
Centralidade e utilidade nas revisões de produtos em *e-Markeplaces*: uma visão analítica numa área da Amazon

Eva Sónia Ferreira Pinto

Dissertação

Mestrado em Economia e Administração de Empresas

Orientado por

Professor Doutor Pedro José Ramos Moreira de Campos

Professora Doutora Ana Isabel Perdigão Lopes Pereira Torres

2018

Agradecimentos

Para os que me apoiaram e pelo que me ensinaram sobre não desistir

Resumo

Em muitas plataformas de comércio eletrónico, as comunidades de utilizadores partilham informação sobre os produtos, na forma de comentários (*reviews*), atribuindo pontuação à utilidade (*helpful*) desses mesmos comentários e ao produto (*ratings*). Apesar do crescente número de *reviews online*, o impacto entre o número de *reviews* e a classificação dos produtos continua pouco explorado. Ainda não se sabe como é a relação do número de *reviews* com a pontuação atribuída pelos utilizadores ao produto e com a utilidade das mesmas. Esta investigação introduz e examina empiricamente os efeitos potenciais da quantidade de informação fornecida, com a classificação atribuída e com a utilidade da mesma. Para responder à nossa investigação, usamos um conjunto de dados disponíveis publicamente no *e-Marketplace* da Amazon.com.

Os nossos resultados apresentam evidências significativas de que não há uma relação clara entre o aumento do *rating* do produto e o número de *reviews*. Isto é, conclui-se que os consumidores comentam um produto, independentemente da sua qualidade. Logo, um elevado número de *reviews*, não implica um produto com boa classificação. Por outro lado, quando os *reviews* são úteis para a tomada de decisão dos consumidores, a tendência é que o número de *reviews* aumente.

Embora esta investigação se revele mais um passo na análise das *reviews*, reconhecemos que a abordagem utilizada tem limitações, sendo a principal, a análise única de uma categoria de produtos específica e não o *rol* de produtos disponíveis no *e-Marketplace* da Amazon. Por conseguinte, como sugestão para trabalhos futuros, sugere-se que se analise uma diferente categoria de produtos (livros, por exemplo), para verificar se esta apresenta resultados semelhantes àqueles que obtivemos.

Palavras-chave: *reviews*, centralidade, *rating*, utilidade, *e-marketplace*

Abstract

In several e-commerce platforms, the user community shares information about the products in the form of reviews, assigning a score to its utility and to the product itself. In spite of the growing number of online reviews, the impact between the number of these and the rating of the products is yet under explored. It's still unknown how the connection between the number of reviews works with the score assigned to the product and its utility. This research presents and empirically analyses the potential effects of the quantity of given information, with the assigned score and its value. To answer our research, we used a set of available data on the Amazon.com Marketplace.

Our results present meaningful evidence that there is no clear relationship between the increase of the product rating and the number of reviews. We conclude that consumers comment on a product regardless of its quality. Thus, even if a product has an elevated number of reviews, it doesn't necessarily mean it has a good rating. On the other hand, when the reviews are useful for the decision-making of consumers, the rating of the products tends to be higher.

Although this research turns out be one step forward in the analysis of the reviews, we recognize that this approach has limitations. The main one is the single analysis of a specific category of products and not all the available products on the Amazon Marketplace. Therefore, as a recommendation for further work, it is suggested to analyse a different category of products (books, for example), to confirm if the presented results are similar to the ones we achieved.

Key-words: Reviews, centrality, rating, helpful, E-commerce

Índice

| | | |
|--------|--|----|
| 1. | Introdução | 1 |
| 2. | Revisão de Literatura | 4 |
| 2.1. | Sistemas de Recomendação..... | 4 |
| 2.2. | A Introdução dos Sistemas de Recomendação | 5 |
| 2.2.1. | Por que é que os Sistemas de Recomendação ganharam popularidade? | 6 |
| 2.3. | Os Tipos de Sistemas de Recomendação Mais Utilizados..... | 6 |
| 2.4. | Limitações dos Sistemas de Recomendação | 10 |
| 2.5. | As Redes Sociais e Centralidade de Produtos..... | 11 |
| 2.5.1. | Centralidade de Grau | 13 |
| 2.5.2. | Centralidade <i>Eigenvector</i> | 14 |
| 2.5.3. | Centralidade de Intermediação (<i>Betweenness Centrality</i>) | 14 |
| 2.6. | Modularidade..... | 15 |
| 2.7. | <i>Reviews</i> , <i>Rating</i> e <i>Helpful</i> | 15 |
| 2.7.1. | <i>Reviews</i> | 15 |
| 2.7.2. | <i>Helpful</i> | 17 |
| 2.7.3. | <i>Rating</i> | 17 |
| 2.8. | Limitações das <i>Reviews</i> | 18 |
| 3. | Questões de Investigação, Hipóteses, Metodologia e Dados | 20 |
| 3.1. | Objetivo, Questões Centrais e Hipóteses..... | 20 |
| 3.2. | <i>Clustering</i> | 21 |
| 3.2.1. | Análise Hierárquica | 21 |
| 3.2.2. | Análise não hierárquica – <i>K-Means</i> | 22 |
| 3.3. | Base de Dados | 22 |
| 3.4. | <i>Software</i> Utilizado | 23 |
| 3.4.1. | <i>Software Gephi</i> | 24 |

| | | |
|--------|--|----|
| 3.4.2. | <i>Software R</i> | 25 |
| 4. | Resultados | 26 |
| 4.1. | Análise da Centralidade..... | 26 |
| 4.2. | Análise dos <i>Clusters</i> | 28 |
| 4.3. | Teste das Hipóteses de Investigação..... | 30 |
| 4.3.1. | Relação entre a centralidade e o <i>rating</i> do produto | 31 |
| 4.3.2. | Relação entre a centralidade da <i>review</i> e a sua <i>helpful</i> | 32 |
| 4.3.3. | Impacto da centralidade da <i>review</i> no <i>rating</i> | 33 |
| 4.3.4. | Impacto da centralidade da <i>review</i> na <i>helpful</i> | 37 |
| 5. | Conclusão, Limitações e Sugestões para trabalhos futuros..... | 39 |
| | Referências Bibliográficas..... | 41 |
| | Anexos..... | 51 |

Índice de tabelas

| | |
|---|----|
| Tabela 1- Exemplos de sistemas de recomendação..... | 8 |
| Tabela 2 - Descrição da base de dados..... | 23 |
| Tabela 3 - Análise de clusters..... | 29 |
| Tabela 4 - Matriz de correlação | 31 |

Índice de figuras

| | |
|---|----|
| Figura 1 - Rede Social | 12 |
| Figura 3 - Análise de dispersão entre eigencentality e o rating..... | 32 |
| Figura 4 - Análise de dispersão entre a centralidade e o helpful..... | 33 |
| Figura 5 - Comandos utilizados para obter a árvore de regressão | 34 |
| Figura 6 – Regras obtidas a partir da árvore de regressão | 35 |
| Figura 7- Árvore de regressão..... | 36 |

1. Introdução

O comércio eletrónico vem crescendo a largos passos e segundo as previsões do *eMarketers*, as vendas mundiais do comércio eletrónico no retalho atingirão os 4 triliões de dólares até 2021 (eMarketer, 2018). Criando uma analogia entre o comércio eletrónico e uma loja física, a estrutura eletrónica não é definida por corredores e/ou por prateleiras, mas sim, por informações úteis, em que os produtos ficam interligados, percorrendo várias páginas.

Quando utilizados de forma eficaz, estas informações úteis fornecem sugestões aos utilizadores com base nas preferências de outros utilizadores, i.e. com base no perfil do cliente construído a partir da informação do seu histórico de compra ou de pesquisa nos *sites*. Estas informações, onde se incluem os sistemas de recomendação, têm mostrado, primariamente, o seu valor nos *sites* de comércio eletrónico como a Amazon.com e o eBay, fornecendo recomendações algorítmicas (Kim *et al.*, 2017). Contudo, Li (2016) reconhece que os sistemas de recomendação nem sempre funcionam da forma mais correta, podendo o produto recomendado não estar relacionado com o desejado. Torna-se assim, pertinente estudar outras medidas inseridas, recentemente, nos *sites* de comércio eletrónico: tais como, o *rating* (pontuação do produto), os *reviews* (número de *reviews*) e a utilidade das mesmas (*helpful*).

Nas últimas décadas, com o desenvolvimento da *internet* e o crescimento do comércio eletrónico, os dados gerados pelos utilizadores aumentaram drasticamente e à medida que mais informação é disponibilizada *online*, localizar os produtos/serviços (por exemplo, hotéis, filmes, etc), tornou-se numa tarefa mais difícil e complexa para o utilizador (Centeno *et al.*, 2018).

Usualmente, recorreremos à ajuda ou opinião de outros para obtermos informação que nos permite tomar a melhor decisão. As pessoas que consultamos podem ser amigos, membros da família ou, os mais populares agora – revisores *online* de produtos. (Resnick & Varian, 1997).

As revisões (ou *reviews* dos clientes *online*) são comentários sobre os produtos colocados por utilizadores e tornaram-se cada vez mais importantes no processo de tomada de decisão dos consumidores. *Sites* como a Amazon.com permitem que os utilizadores comentem os produtos disponíveis na plataforma, fornecendo *feedback* útil a outros utilizadores sobre os

atributos ou *performance* dos produtos (Meo *et al.*, 2017). Esta partilha de informação entre os utilizadores, cria redes de produtos, isto é, se um utilizador comenta vários produtos, estes ficam, de certo modo, ligados entre si.

A literatura sobre o *rating* (ou seja, a pontuação de um produto que é uma medida de precisão sobre a qualidade de um produto) e os determinantes das *reviews* e da utilidade tem apresentado progressos graduais, no que concerne a projetar e validar algoritmos para calcular a pontuação da utilidade da *review* e a classificação do produto. Contudo muito pouco se sabe sobre a relação entre a classificação do produto e o número de *reviews*.

Dado o enorme impacto das *reviews* de produtos nas compras dos consumidores, as empresas podem manipular *reviews* para aumentar as vendas, publicando críticas favoráveis e/ou eliminando críticas negativas. Uma abordagem implementada para combater as *reviews* falsas, passa por identificar a confiabilidade do *reviewer* com avaliação da utilidade da mesma, na esperança que os utilizadores votem nas *reviews* mais úteis. Devido a estas fragilidades existentes, torna-se relevante estudar a utilidade dos mesmos e decifrar até que ponto a quantidade de *reviews* é indicador da qualidade do produto. Esta investigação tem como objetivo preencher esta lacuna, de forma a responder às seguintes questões: A pontuação do produto está relacionada com o número de *reviews*? E com a utilidade das mesmas?

Partindo do pressuposto de que os *ratings* elevados, estão associados (*à priori*) a uma centralidade (número de ligações de um produto a outros) de *reviews* elevada, os produtos portadores de melhores classificações, são o que possuem mais comentários.

Para responder às questões de investigação, usamos um conjunto de dados disponíveis publicamente pela empresa Amazon.com¹ (He & McAuley, 2016). Esta base de dados contém mais de 150 milhões de *reviews* e para tornar o trabalho exequível, iremos focar-nos numa categoria específica - instrumentos musicais. O código do produto, a *helpful*, o *rating* e o texto de *review* são algumas das informações disponíveis na base de dados que utilizaremos como variáveis do estudo.

Este estudo encontra-se estruturado da seguinte forma: No Capítulo 2, é feita a revisão da literatura, onde são apresentados os principais conceitos de interesse, discute-se a crescente

¹ Base de dados: <http://jmcauley.ucsd.edu/data/amazon/>

expansão dos sistemas de recomendação, assim como as componentes de avaliação do produto apresentadas na plataforma Amazon.com. No Capítulo 3, descrevemos a metodologia da seleção dos dados usados no modelo da rede dos produtos, o conjunto de análises e *softwares* utilizados. No Capítulo 4, apresentamos os resultados das análises que dão resposta às questões de investigação através dos testes às hipóteses do estudo. Por fim, no Capítulo 5 são expostas as principais conclusões e limitações do estudo e sugeridos potenciais trabalhos futuros.

2. Revisão de Literatura

Nesta secção apresentamos os conceitos de interesse que serão examinados nesta investigação. Introduzimos o surgimento dos sistemas de recomendação e a sua crescente importância (secções 2.1-2.4). Em seguida, descrevemos as diferentes abordagens para medir a centralidade e a modularidade (secção 2.5-2.6). Posteriormente, discutimos a questão do *rating*, das *reviews* e da utilidade das mesmas, e explicamos como estas estão relacionadas (secção 2.7). Por fim, terminamos com a secção 2.8, revelando as limitações existentes nas *reviews*.

2.1. Sistemas de Recomendação

Com o rápido desenvolvimento da internet, milhões de utilizadores enfrentam um elevado conjunto de informações e para reduzir a complexidade do processo de escolha, surgiram os sistemas de recomendação. Segundo Burke (2002), um sistema de recomendação é um sistema com capacidade de realizar recomendações individualizadas ou direcionar o utilizador, de forma personalizada, a produtos ou serviços, que atendam às necessidades do consumidor perante um largo espectro de opções.

Estes sistemas identificam-se como um tipo de *software* que apresenta uma lista de recomendações ao utilizador de acordo com as suas preferências, carecendo de dados de várias fontes, como formulários, dados de *data warehouse* já existentes e dados demográficos. É possível uma compilação dos dados do cliente com os dados do produto através do *website* do comércio eletrónico – ponto de integração (Felden & Chamoni, 2007).

Os sistemas fornecem sugestões de produtos personalizados ou serviços, como livros, música, transporte ou mesmo pessoas, com base em informação sobre o utilizador ou sobre o produto (Bodapati, 2008). Para Adomavicius & Tuzhilin (2005), este tipo de sistemas surgiu para ajudar os utilizadores a dar resposta ao crescimento de informação disponível nestas plataformas e que se tornaram muito populares nos últimos 15 anos (Billsus & Pazzani, 1998; Koren, 2009; Sarwar *et al.*, 2000).

Hoje, estes sistemas de recomendação são usados em empresas detentoras de muita informação, como a Google (J. Liu *et al.*, 2010), Twitter (Ahmed *et al.*, 2013), LinkedIn (Rodriguez *et al.*, 2012), Netflix (Steck, 2013), Amazon.com e o Alibaba (Kong *et al.*, 2017),

fornecendo resultados de recomendações personalizados para produtos de interesse com base nos dados históricos dos clientes.

As pesquisas referem que estes sistemas aumentam a satisfação do consumidor e também o número de vendas (Fleder & Hosanagar, 2009). Logo, uma pequena melhoria neste tipo de sistemas pode alavancar maiores receitas (L.-S. Chen *et al.*, 2008; Kong *et al.*, 2017; Q. Zhao *et al.*, 2015) e minimizar riscos de venda (Lee *et al.*, 2013).

Os sistemas de recomendação têm alcançado muito sucesso comercial e estão a tornar-se cada vez mais populares numa ampla variedade de aplicações práticas (Kong *et al.*, 2017; Q. Zhao *et al.*, 2015). No entanto, os académicos e as empresas continuam a pesquisar formas de aumentar a sua eficácia (Hennig-Thurau *et al.*, 2012). Por exemplo, a empresa Netflix ofereceu 1 milhão de dólares a qualquer pessoa que aumentasse a eficácia do sistema de recomendação em 10% (Lohr, 2009).

Estes sistemas são indispensáveis para adaptar experiências para os utilizadores com o objetivo de gerar sugestões de conteúdos (Kong *et al.*, 2017). A formulação mais comum baseia-se na noção de classificações, ou seja, os sistemas de recomendação estimam produtos que os utilizadores ainda não consumiram, com base nos produtos já adquiridos e nas avaliações (com base em classificações) de outros utilizadores (Adomavicius & Kwon, 2012).

2.2. A Introdução dos Sistemas de Recomendação

Os sistemas de recomendação foram introduzidos no final dos anos 70, desenvolvendo inicialmente o sistema de *Grundy* (Rich, 1979) que construía modelos com informação limitada. Mais tarde, no início dos anos 90, deram-se os primeiros passos no que concerne à praticabilidade comercial com o modelo *Tapestry* (*Tapestry Information Project*) que utilizava filtragem colaborativa para a recomendação (Goldberg *et al.*, 1992).

O *Tapestry* permite que os utilizadores avaliem o conteúdo da mensagem e indiquem com as classificações “bom” ou “mau”, se esta lhes foi útil. Desta forma, o sistema identifica os utilizadores semelhantes (i.e. indivíduos com preferências similares que adquirem o mesmo género de produtos) e oferece recomendações baseadas nessa similaridade (Q. Zhao *et al.*, 2015). Os dados recebidos no sistema são armazenados e ficam acessíveis para outros

utilizadores, por conseguinte, o utilizador pode filtrar a mensagem recebida com base no conteúdo e nas opiniões dos outros utilizadores (Goldberg *et al.*, 1992).

Por conseguinte, os sistemas de recomendação confiam no *feedback* do utilizador (por exemplo, na forma de um *rating*), a fim de construir modelos ricos e de alta fiabilidade das preferências do utilizador. Tais sistemas são então avaliados em termos da sua capacidade de prever classificações ou produtos de acordo com o comportamento real dos utilizadores (T. Zhao *et al.*, 2017).

2.2.1. Por que é que os Sistemas de Recomendação ganharam popularidade?

Conforme referido previamente, o comércio eletrónico tem crescido a largos passos, tendo atingido 2 304 triliões de dólares em vendas no ano de 2017, o que significa um aumento de 24,8% face ao ano anterior e prevê-se que as vendas mundiais do comércio eletrónico no retalho atinjam os 4 triliões de USD até 2021 (eMarketer, 2018). Desta forma, surge a necessidade de organizar a informação de modo a que esta não se torne numa sobrecarga para o utilizador.

Os sistemas de recomendação são ferramentas importantes no comércio eletrónico, pois fornecem aos utilizadores recomendações personalizadas e permitem que estes descubram novos produtos para o mesmo fim com uma pesquisa simplificada (Kim *et al.*, 2017). Complementarmente, auxiliam os utilizadores em áreas de compra desconhecidas pelo utilizador, (como por exemplo, tecnologia) e sugerem produtos complementares (*cross-selling*), sem que o utilizador despenda mais tempo na pesquisa.

Somando ao conjunto dos benefícios já mencionados - tempo e esforço de pesquisa reduzidos -, adicionamos ainda a indicação de produtos mais ajustados às necessidades dos utilizadores que melhoram as decisões de compra (Gomez-Urbe & Hunt, 2015). Consequentemente, estas decisões são penosas em termos de tempo (Kim *et al.*, 2017).

2.3. Os Tipos de Sistemas de Recomendação Mais Utilizados

Os tipos de recomendação possuem formas distintas (Schafer *et al.*, 2011) e geralmente são classificados em três categorias baseadas na sua abordagem de recomendação: abordagens baseadas em conteúdo (Kabbur *et al.*, 2013; S.-T. Park *et al.*, 2006), colaborativas (Patrick &

Fischer, 1970; Salakhutdinov & Mnih, 2007) e híbridas (Adomavicius & Tuzhilin, 2005; Lah *et al.*, 2017).

As pesquisas recentes sobre sistemas de recomendação evidenciam o desenvolvimento de algoritmos que predizem as preferências dos utilizadores com um erro mínimo, aplicando técnicas de filtragem colaborativa baseadas em conteúdo (M. Li *et al.*, 2007) ou métodos de filtragem híbrida (D. Liu *et al.*, 2009).

Os sistemas baseados em conteúdo recomendam produtos semelhantes aos produtos que o utilizador adquiriu/gostou no passado, tendo em conta o seu histórico, e simultaneamente, traça o perfil mais adequado a partir de comentários, preços, entre outros (Mcnamee *et al.*, 2002; Q. Zhao *et al.*, 2015). As preferências do utilizador são atualizadas continuamente com base nos comentários que o utilizador fornece nos produtos recomendados. Por exemplo, se um utilizador da Amazon.com adquiriu muitos livros românticos, então o conteúdo com base no sistema de recomendação sugere livros no banco de dados como tendo o género “romântico” (Lah *et al.*, 2017). Ainda, se um utilizador pesquisa um computador específico (produto), o sistema reúne informações sobre esse produto e pesquisa na base de dados computadores com atributos/características semelhantes, como o preço, velocidade do CPU e a capacidade de memória (Portugal *et al.*, 2017).

Os sistemas de recomendação de filtragem colaborativa dominam na popularidade, sendo o sistema mais comum nos dias de hoje (Kim *et al.*, 2017). Baseiam-se no pressuposto de que utilizadores com históricos semelhantes (ou seja, “vizinhos”), têm preferências idênticas para novos produtos. A título de exemplo, numa loja de música *online*, o sistema de informação tem acesso a todos os dados do utilizador, como idade, país, cidade e músicas compradas (Portugal *et al.*, 2017), e com esta informação o sistema identifica os utilizadores que compartilham a mesma preferência de música, produzindo assim, recomendações destes produtos aos utilizadores semelhantes (Canny, 2002; Lim & Teh, 2007).

As técnicas de filtragem colaborativa funcionam bem quando há informações suficientes sobre o *rating* do produto (Su & Khoshgoftaar, 2009). No entanto, a sua eficácia é limitada quando os comentários são reduzidos (Esparza *et al.*, 2011). Por si só, as abordagens baseadas em conteúdo e de filtragem colaborativa sofrem uma série de inconvenientes, mas juntos formam uma poderosa estratégia de recomendação híbrida (Smyth *et al.*, 2005).

A abordagem híbrida combina métodos baseados em conteúdo e de filtragem colaborativa de várias formas. Embora seja um sistema de implementação complexo, geralmente, obtém melhores resultados do que um método de filtragem isolado, uma vez que as vantagens de ambos os sistemas se combinam (Basilico & Hofmann, 2004). Por exemplo, um sistema de recomendação numa rede social, utiliza a filtragem colaborativa quando recomenda produtos que os utilizadores semelhantes adquiriram/gostaram, por sua vez, um sistema de recomendação baseado em conteúdo, recomenda produtos com base no histórico de compras do utilizador, o que gostou/recomendou (Portugal *et al.*, 2017). Na Tabela 1 apresenta-se uma descrição dos tipos de recomendação e a forma como são utilizados.

Tabela 1- Exemplos de sistemas de recomendação

| Website | Tipo de Sistema de Recomendação | Descrição | Metodologia |
|----------------|--|---|---|
| Youtube | Filtragem baseada em Conteúdo | O sistema de recomendação de vídeos no Youtube é fornecer recomendações personalizadas aos seus utilizadores. | Para cada vídeo que o utilizador está a ver, o sistema prevê o próximo vídeo que este irá ver. Isso é combinado com informações adicionais sobre o utilizador, para criar um “caminho” de vídeos para o utilizador ver. |
| Amazon.com | Filtragem Colaborativa | O sistema de recomendação da Amazon é baseado nos seguintes elementos: - Compras passadas do utilizador; - Produtos no carrinho de compras; - Produtos que os utilizadores avaliaram e gostaram; - Produtos que os utilizadores visualizaram e compraram. | Para cada produto, a Amazon.com constrói um conjunto de produtos relacionados. Sempre que um produto é comprado, a Amazon.com recomenda aos “vizinhos”. Os produtos são categorizados como: “Você viu”, e “Clientes que viram isto também viram isto” ou “Frequentemente comprados juntos”. |
| LinkedIn | Filtragem Colaborativa | O LinkedIn é um <i>site</i> de rede de negócios e ofertas de trabalho. Para conectar pessoas, o LinkedIn faz | O perfil de cada membro no LinkedIn tem “Pessoas que viram o seu perfil também viu este perfil”. |

| | | | |
|---------|-------------------|---|---|
| | | uso extensivo da filtragem colaborativa. | Os conjuntos de filtragem colaborativa, existem não apenas para pessoas, mas também para ofertas de emprego e empresas. As sugestões de navegação são componentes de <i>engagement</i> no <i>site</i> . |
| Netflix | Filtragem Híbrida | Faz recomendações de filmes, comparando os filmes que foram vistos e pesquisados pelos utilizadores semelhantes (filtragem colaborativa), bem como os filmes que o próprio utilizador considerou com um alto <i>rating</i> (filtragem baseada em conteúdo). | A Netflix oferece recomendações de filmes que os utilizadores possam gostar, com base nas classificações fornecidas pelos outros utilizadores. |

Fonte – Tabela adaptada de Kim *et al.* (2017)

Usando uma abordagem de filtragem colaborativa ou híbrida, os sistemas de recomendação devem reunir informações sobre o utilizador para desenvolver recomendações, sendo que esta recolha pode ser desempenhada explícita ou implicitamente. Na forma explícita, os dados são recolhidos quando os utilizadores são os próprios clientes que fornecem as informações (registo num serviço *online* – nome, idade, morada, país). Outra forma, é quando o utilizador expressa as suas preferências fornecendo classificações aos produtos através de valores numéricos ou de um “gosto” no Facebook.

Quanto à forma implícita, esta acontece na recolha de dados indiretos sobre o utilizador. Tomando como exemplo a troca mensagens do utilizador com o servidor da loja *online* através do seu computador pessoal, o sistema de recomendação pode guardar dados como: motor de busca utilizado e país do utilizador. Sendo ainda possível, monitorizar os registos e o passo a passo que o utilizador percorre no *website* (Portugal *et al.*, 2017).

Além disso, os sistemas de recomendação também podem ser classificados com base na sua natureza algorítmica em abordagens heurísticas ou baseados em memória (Adomavicius & Tuzhilin, 2005). As técnicas heurísticas, geralmente, geram recomendações com base na atividade do utilizador anterior (por exemplo, no *rating*), e uma das técnicas mais comuns é

baseada na abordagem do vizinho (mencionada acima), que procura os utilizadores semelhantes (Breese *et al.*, 1998; Sarwar *et al.*, 2001).

Alguns estudos consideram as recomendações baseadas em redes sociais, i.e com base em relações de confiança e amizade (L. Chen & Wang, 2013; B. Liu & Sun, 2013), para aumentar a precisão da recomendação. Uma relação de confiança traduz-se num *link* numa rede social para o amigo conectar-se ou seguir a conexão, ou seja, um utilizador confiará e considerará mais credível uma recomendação de alguém da sua rede social, do que de um estranho ou de um algoritmo (Kim *et al.*, 2017).

Existem ainda as recomendações conscientes de risco (Lee *et al.*, 2013), que são um subconjunto de recomendações relacionadas com o contexto e onde constam informações críticas que estão disponíveis, por exemplo, a vida do utilizador. É consciente de risco porque uma decisão errada pode ameaçar a vida do utilizador ou causar danos, como a prescrição de medicamentos, ou a compra e venda de ações.

No entanto, estes métodos apresentam limitações, especialmente quando o utilizador possui poucos dados históricos (L. Chen *et al.*, 2015). O próximo ponto examinará essas limitações.

2.4. Limitações dos Sistemas de Recomendação

Apesar dos métodos apresentados acima alcançarem manifestamente bons resultados, o núcleo de estratégias de recomendação também deve ser adaptado para lidar com gostos únicos de utilizadores, proporcionando uma recomendação personalizada. Assim, estes algoritmos podem ser ineficientes, pois não conseguem atingir o pensamento humano, ou identificar outras características psicográficas dos indivíduos, fortemente determinantes do comportamento do consumidor moderno – consumidor que frequenta *blogs* de opinião e interage com as marcas através de uma compra *online*, por exemplo.

Os utilizadores são mais propensos a ter uma recomendação de outra pessoa (*reviews*), em vez de um algoritmo, devido à incapacidade latente de não estabelecerem uma conexão emocional com o utilizador. De acordo com L. Liu *et al.* (2012), o processo de análise pode ser definido por duas etapas: 1) decisão do consumidor na leitura da *review* e 2) processamento da informação da *review*, que persuade a decisão de compra com base na utilidade desta.

A percepção das *reviews* influencia o comportamento dos utilizadores, e estes, presumem que as críticas expostas nos respetivos produtos/serviços são escritas pelos próprios – pessoas com que se identificam (Steffes & Burgee, 2009). Por esse motivo, os utilizadores confiam nas mensagens de outros utilizadores e preferem-nas face às criadas comercialmente (Chakravarty *et al.*, 2010). São várias as razões que levam as pessoas a ler as *reviews*, desde a obtenção de informações até à construção de relações numa comunidade *online*, afetando o comportamento do leitor (Burton & Khammash, 2013; Hennig-Thurau *et al.*, 2003).

Face às limitações dos sistemas de recomendação aqui apresentadas, torna-se pertinente estudar outras medidas inseridas, recentemente, nos *sites* de comércio eletrónico: tais como, o *rating* (pontuação dos produtos), a centralidade das *reviews* (número de *reviews*) e a utilidade das mesmas (*helpful*). Estas medidas serão definidas e discutidas no próximo ponto, e posteriormente, sujeitas a análise.

2.5. As Redes Sociais e Centralidade de Produtos

Uma rede social é uma ligação de indivíduos ou grupos conectados por algumas relações. Esta ligação pode ser *online* ou *offline* (Das *et al.*, 2018). Na teoria, a rede social é definida como um conjunto de entidades sociais discretas (chamadas de nós e/ou vértices) e por ligações (também designadas por arestas). As entidades ou “nós” numa rede social são muitas vezes chamados de atores, e estes podem ser indivíduos, organizações ou outras unidades coletivas (Torres & Martins, 2014).

Os atores estão ligados entre si por laços sociais (frequentemente, chamados de relações ou relacionamentos), podendo estes ser formais ou informais (Bulte & Stremersch, 2004). E, ainda, dois nós (vértices) ligados entre si são considerados vizinhos e o número de elementos do sistema correspondem ao número de nós (Barabási, 2014). Por exemplo, na Figura 1 estão presentes oito nós (nodes) e nove ligações (*edges*/arestas) que formam uma rede social.




Figura 1 - Rede Social
Fonte - Das *et al.* (2018)

A análise de redes sociais é uma ferramenta útil para estudar o relacionamento entre entidades sociais, como famílias, corporações ou nações (Wasserman & Faust, 1994), que nos ajudam a examinar a estrutura e a localizar propriedades como a centralidade, relações de equivalência, equilíbrio estrutural, centralização e coesão estrutural que foram desenvolvidos para descrever as características da rede (Hanneman & Riddle, 2005).

Há redes em todo o lado e em todo o tipo de problemas. O exemplo de uma rede de transportes: estradas, comboios, tráfego aéreo; rede de distribuição: energia elétrica, água, gás; ainda, como rede abstrata, temos o exemplo dos organigramas. Isto é, aplicando o processo da rede a uma rede de transportes, os nós são os aeroportos, estações, cruzamentos, as arestas representam estradas, carris, pontes, e o fluxo da rede exibe as cargas, veículos, passageiros.

O suporte das redes sociais é imprescindível, dado que o utilizador confiará mais numa recomendação de uma pessoa da sua rede social ao invés de um estranho ou de um algoritmo. Esse mesmo utilizador tem mais propensão para procurar e mostrar interesse nessa rede social. Por exemplo, no Spotify os utilizadores podem recomendar músicas para os seus amigos no Facebook (Kim *et al.*, 2017).

O contexto dos utilizadores pode ser partilhado numa rede e as centralidades desta podem ser usadas para descrever os fluxos do contexto da rede (Ha & Lee, 2017). Os estudos sobre sistemas de recomendação utilizam ferramentas poderosas (chamadas índices de centralidade) para determinar a importância de um nó (Wasserman & Faust, 1994). Segundo Jackson (2008), a centralidade é usada para definir a importância de um nó numa rede. A

relevância é dada pela informação que se encontra no mesmo, pelas interligações criadas por este e pela facilidade que tem em comunicar com outros nós, isto é, quanto mais informação o nó tiver, mais influente este será, consequentemente, mais próximo e por sua vez, mais central.

A centralidade de um nó é definida pelo número de ligações de um ator a outros atores com elevadas ligações. Usualmente, a centralidade está vinculada à capacidade de influenciar os restantes por deter maior volume de informação (Mizruchi, 1994). Segundo Zanin *et al.* (2016), a centralidade é considerada um dos paradigmas mais populares nas ciências sociais e comportamentais, particularmente na economia, na gestão e no marketing, sendo as medidas mais utilizadas: centralidade de grau, centralidade *eigenvector* e a centralidade de intermediação (*betweness centrality*) que se descrevem seguidamente.

2.5.1. Centralidade de Grau

A centralidade de grau é a medida mais utilizada (Wasserman & Faust, 1994), esta indica o número de nós diretamente ligados a um determinado nó. Nesta forma de centralidade estão indicadas o número de ligações incidentes num determinado nó em comparação com outros nós na rede (os nós com maior centralidade). No nível agregado, as redes com muitos nós de alto grau estão mais conectadas. No nível individual, a centralidade de um nó na rede está positivamente correlacionada com a sua capacidade de disseminar conteúdo e ideias para toda a rede.

Com este género de centralidade, existem dois ramos que subdividem-se entre a centralidade *in-degree* e *out-degree* (Wasserman & Faust, 1994). No *in-degree* estão presentes o número de ligações que um nó recebe, enquanto que no *out-degree* estão apresentadas as ligações que saem de um nó para os outros, ou seja, as que o nó envia.

Matematicamente, a centralidade de grau $C_D(x)$ é definida por $C_D(x) = dx$ onde dx é o grau de um nó x . Então, centralidade de grau é definida por:

$$C_D'(x) = \frac{d_x}{n-1} \quad (1)$$

Onde n revela o tamanho da rede.

A principal limitação da centralidade de grau é o facto de esta medida apenas recolher informação dos relacionamentos adjacentes, revelando apenas a centralidade local dos nós.

2.5.2. Centralidade *Eigenvector*

A centralidade *eigenvector* (vetor próprio) baseia-se em noções de influência, *ranking* e prestígio dos vizinhos do nó que pretendemos analisar. Quer isto dizer, que a centralidade de um nó é medida através da importância dos vizinhos aos quais o nó está ligado, pois têm acesso facilitado a informação e fontes de influência. Sendo este índice de centralidade, uma variável de alocação que descreve a influência geral de um nó em toda a rede, o que o torna importante e o seu impacto na *reviews* tem que ser mais estudado (Muller & Peres, 2018).

A abordagem de Bonacich (2007) é bastante adequada para o cálculo da centralidade, uma vez que não tem só em conta a centralidade dos vizinhos, mas também a qualidade dos mesmos. Seja A a matriz de adjacência, tal que $a_{ij} = 1$ se o nó i estiver ligado ao nó j e $a_{ij} = 0$. Então, a centralidade do vetor para o nó i é dada por:

$$Ax = \lambda x, \lambda x_i = \sum_{j=1}^n a_{ij} x_j \quad i = 1, 2 \dots n \quad (2)$$

Esta medida de centralidade baseia-se no facto de que um nó é importante se o vizinho também o for.

2.5.3. Centralidade de Intermediação (*Betweness Centrality*)

A centralidade de intermediação, também conhecida por *betweness centrality*, mede até que ponto um nó é um importante intermediário entre as ligações de outros nós na rede, isto é, reflete o número de caminhos mais curtos que ligam pares de nós, que passam por esse nó específico. Estes nós são detentores de uma centralidade muito elevada, pois, ligam comunidades, que de outra forma não estariam ligadas (Everett & Valente, 2016). Esta abordagem foi proposta por (Freeman, 1978) com o propósito de medir e controlar a importância que um individuo possui numa rede social humana entre outros seres humanos. Partindo do pressuposto que as ligações entre os nós seguem sempre o caminho mais curto.

A centralidade de intermediação $C_B(x)$ de um vértice x na rede é dada por:

$$C_B(x) = \sum_{y \neq z \in N} \frac{\sigma_{st}(x)}{\sigma_{st}} \quad (3)$$

Onde σ_{st} indica o número de caminhos mais curtos entre s e t contendo x , e σ_{st} denota o número de todos os caminhos mais curtos entre s e t na rede.

2.6. Modularidade

A modularidade deteta as comunidades existentes numa rede social e avalia a divisão feita na rede (J. Newman, 2006). Este algoritmo é composto por duas fases, na primeira cada nó i representa uma comunidade diferente, isto é, o número de comunidades corresponde ao número de nós. Na segunda fase, consideram-se os vizinhos de cada nó i , este é movido para a comunidade onde obtiver maiores ganhos, ou seja, avalia-se o ganho de modularidade do nó i , para o nó j . Matematicamente, é definida por:

$$\Delta Q = \left[\frac{\Sigma_{in} + K_{i,in}}{2m} - \left(\frac{\Sigma_{tot} + k_i}{2m} \right)^2 \right] - \left[\frac{\Sigma_{in}}{2m} - \left(\frac{\Sigma_{tot}}{2m} \right)^2 - \left(\frac{k_i}{2m} \right)^2 \right] \quad (4)$$

Onde Σ_{in} representa o peso das arestas na comunidade C , Σ_{tot} é a soma dos pesos das arestas incidentes no nó i , $k_{i,in}$ é a soma dos pesos das arestas partindo do nó i para todos os nós em C e m , é a soma dos pesos de todas as arestas da rede. Este processo é repetido até a modularidade máxima ser alcançada.

2.7. Reviews, Rating e Helpful

A maioria das interações em plataformas eletrónicas envolve diversos tipos de entidades (geralmente, heterógenas), como clientes, vendedores e instituições públicas/privadas que geralmente não possuem históricos de relacionamento entre si. Estes relacionamentos são construídos na forma de *feedback* – *reviews*, *ratings* e *helpful*.

2.7.1. Reviews

As *reviews* dos consumidores *online* são uma fonte muito popular de informação sobre produtos e serviços: 72% dos consumidores com idades compreendidas entre 25 a 34 anos

de idade procura informações para recomendações e opiniões antes de comprar bens e serviços (Mintel, 2015). As *reviews* podem ser definidas como qualquer comentário sobre um produto ou serviço escrito por um consumidor (Filieri, 2016).

Os consumidores confiam cada vez mais nas *reviews* para avaliar a qualidade dos produtos quando estão a tomar decisões de compra, sendo que as críticas expostas constituem uma reflexão imparcial sobre a qualidade do produto. A literatura indica que a qualidade, confiabilidade e *helpful* (utilidade) das *reviews* são fatores críticos no impacto do volume de vendas e, que o efeito negativo das *reviews* é maior do que o efeito positivo (Cui *et al.*, 2012).

A partir de 1999, os utilizadores de *sites* de *e-commerce* tiveram a possibilidade de partilhar a sua opinião (usualmente, em forma de texto) sobre um determinado produto (L. Chen *et al.*, 2015). Esta crescente adesão tornou disponíveis opiniões sobre quase tudo, desde produtos a hotéis. No entanto, Xu *et al.* (2015) alertam que um vídeo na *review* é mais útil, credível e persuasível do que uma *review* padrão, escrita e acompanhada com uma imagem, de forma a diminuir as diferenças entre interações físicas e interações através do computador.

Correntemente, a tomada de decisão é realizada dentro de um quadro de rede social em que os indivíduos dependem das opiniões e do apoio dos seus amigos mais próximos, ou de pessoas com interesses semelhantes. Para tal, as *reviews* são publicadas em portais eletrónicos que se destinam à recolha de opiniões para auxiliar a tomada de decisão (Mudambi & Schuff, 2010). Um exemplo conhecido é o *site* de *reviews* do consumidor Epinions.com (Figura 1 – Anexo 1), onde os utilizadores podem escrever críticas sobre os produtos de consumo e atribuir uma classificação aos produtos e às restantes avaliações (Wu *et al.*, 2018).

Segundo Paul *et al.* (2017) a maioria dos *websites* de comércio eletrónico facilita a tomada de decisão com *reviews* e *ratings* (classificações) atribuídas pelos próprios utilizadores. Para Bartosiak & Piccoli (2016), dos muitos efeitos das *reviews*, o efeito persuasivo é o principal, uma vez que as *reviews*, devem influenciar os utilizadores e estimulá-los a agir. No contexto comercial, essa ação corresponde à compra (ou não) para opiniões positivas (ou negativas).

Assim, vários investigadores concordam que as *reviews* influenciam os processos de tomada de decisão e afetam o comportamento dos indivíduos (Duan *et al.*, 2008; Hong & Park, 2012; Litvin *et al.*, 2008). Ainda, nos estudos de diversos autores (Gerani *et al.*, 2014; Nguyen *et al.*, 2015; Shimada *et al.*, 2011) verifica-se que os utilizadores dão mais importância às críticas

escritas por clientes reais do que a resumos estatísticos ou mensagens geradas automaticamente (Chakravarty *et al.*, 2010; J. Chen *et al.*, 2016; Zhang, 2015).

Porém, a proliferação das *reviews* e a riqueza de informação disponível gera sobrecarga de informação (McAuley & Leskovec, 2013), dificultando que os consumidores se orientem e determinem quais as informações mais úteis para eles. Como as *reviews* úteis podem aumentar as vendas (Ghose & Ipeirotis, 2011), várias organizações de comércio eletrónico permitem que os consumidores votem na utilidade de cada *review* e, sinalizem para outros consumidores quais as *reviews* mais úteis para avaliar a qualidade e o desempenho do produto.

2.7.2. *Helpful*

Do ponto de vista do negócio, é importante implementar uma escala para classificar a utilidade (*helpful*) das avaliações dos utilizadores para entender as perceções destes em relação aos produtos e/ou serviços (Bartosiak & Piccoli, 2016).

A *helpful* de uma *review* revela o diagnóstico, isto é, a capacidade para outros consumidores compreenderem melhor a qualidade e o desempenho do produto ou serviço (Jiang & Benbasat, 2007). A medida do “*helpful*” desempenha um papel crítico na *review* e na recomendação (Ghose & Ipeirotis, 2011) e, esta necessidade surge pelo facto de um produto popular possuir, habitualmente, muitas *reviews* para o consumidor ler. Assim sendo, as avaliações precisam de ser classificadas e recomendadas para os consumidores.

Nesse sentido, a Amazon.com pediu aos leitores para votarem na utilidade da *review* dos produtos, com o objetivo final de persuadir a decisão do consumidor oferecendo avaliações mais úteis. Segundo Yang *et al.* (2015), a Amazon.com aumenta os lucros anualmente em \$2,7 biliões com esta questão: “Esta *review* foi útil?” (Figura 2 – Anexo 2).

2.7.3. *Rating*

Segundo Bonch *et al.* (2011), a pontuação (*rating*) é uma medida fundamental para garantir o sucesso, a longo prazo, do comércio eletrónico e, para gerir as atividades de *Customer Relationship Management (CRM)*. A par das *reviews*, os *ratings* positivos podem alterar as atitudes das pessoas sobre o produto para o qual as *reviews* pertencem (Hong & Park, 2012).

O *rating* é definido por Steck (2013), como uma medida de precisão sobre a qualidade de um produto onde apenas estão incluídas as classificações observadas, que foram partilhadas pelos utilizadores. Além disso, estes dados são facilmente recolhidos e, estão disponíveis para testes nos sistemas de recomendação.

2.8. Limitações das *Reviews*

Dado o enorme impacto das *reviews* de produtos nas compras dos consumidores, as empresas podem manipular *reviews online* para aumentar as vendas, publicando críticas favoráveis e/ou eliminando críticas negativas. Estima-se assim, que 1/3 das *reviews* dos consumidores que estão na *internet* são falsas (Hu *et al.*, 2011).

Uma diferença de meia “estrela/bolha”² na classificação do produto pode romper o volume de vendas (Anderson & Magruder, 2012) e, num mercado cada vez mais competitivo, as empresas podem considerar a manipulação, a escolha mais acertada (Gössling *et al.*, 2018). Recentemente, a Amazon.com instalou algoritmos que filtram as *reviews* falsas (Zhuang *et al.*, 2018).

Uma abordagem implementada para combater as *reviews* falsas, passa por identificar a confiabilidade do *reviewer* com avaliação da utilidade da mesma, na esperança que os utilizadores votem nas *reviews* mais úteis. Devido à falta de confiança, os utilizadores podem não se sentir confortáveis para partilhar as suas ideias ou interagir com outros utilizadores e, a longo prazo, a tendência é o abandono da plataforma (Bonchi *et al.*, 2011)

Num sentido amplo, a confiança revela quanto está o indivíduo disposto a confiar em algo (ou alguém) (Audun *et al.*, 2007). Este tema foi estudado por Meo *et al.* (2017), tendo os autores concluído que se pode alavancar as relações de confiança para identificar os utilizadores que produzem as *reviews* mais úteis para toda a comunidade.

A literatura sobre os determinantes das *reviews* e da utilidade tem apresentado desenvolvimentos graduais, no que respeita a projetar e validar algoritmos para calcular a

² Padrão atual de apresentação das *reviews* – texto escrito, acompanhado de imagens e classificações numéricas, expressas no formato de estrelas ou bolhas.

pontuação da utilidade da *review* e a classificação do produto (*rating*) – alguns dos trabalhos mais relevantes revistos na literatura encontram-se resumidos na Tabela 1, do anexo 3.

Alguns investigadores começaram a analisar o que torna as *reviews* úteis (Ghose & Ipeirotis, 2011; S. Park & Nicolau, 2015), e estes, reconhecem a importância das características da fonte (*reviewer*), da mensagem (*review*) para influenciar a decisão de um consumidor votar na utilidade de uma *review*. Ainda, Chua & Banerjee (2016), descobriram que a relação entre a qualidade da informação e a utilidade da *review* varia em função do produto e da *review* (favorável, desfavorável e misto). Estas descobertas indicam que o tipo de produto que está a ser estudado também é um fator importante quando se estuda os indicadores da utilidade.

Com base na literatura revista, verificamos que muito pouco se sabe sobre a relação entre a classificação do produto e o número de *reviews*. Esta investigação tem como objetivo preencher esta lacuna, respondendo à seguinte questão: A classificação do produto está relacionada com o número de *reviews*? E com a utilidades das mesmas? Na próxima secção serão desenvolvidas as hipóteses de investigação a testar para responder a estas questões, assim como será apresentada a metodologia de análise dos dados utilizados nesta investigação.

3. Questões de Investigação, Hipóteses, Metodologia e Dados

Neste capítulo apresentam-se as questões de investigação do estudo que tem como objetivo analisar a relação entre a centralidade das *reviews* do produto com o seu *rating* e com a *helpful* das mesmas. Numa segunda análise pretende-se examinar o impacto que a centralidade tem nestas variáveis. Nos próximos subpontos, será feita uma explicação dos objetivos do estudo, formuladas as hipóteses de investigação e apresentada uma caracterização da base de dados, assim como, dos *softwares* utilizados.

3.1. Objetivo, Questões Centrais e Hipóteses

Apesar do crescente número de *reviews online*, o impacto entre o número de *reviews* e o *rating* dos produtos continua pouco explorado. Ainda não se sabe como é a relação do número de *reviews* com o *rating* atribuído pelos utilizadores ao produto e com a utilidade das mesmas. Esta investigação introduz e examina empiricamente os efeitos potenciais da quantidade de informação fornecida, com a classificação atribuída e com a utilidade da mesma.

Para identificar os produtos detentores de um maior número de *reviews* utiliza-se a medida da centralidade. Para tal, desenvolveu-se uma rede de produtos que permite calcular a centralidade, onde os produtos (nós da rede) ficam ligados (arestas) quando o mesmo *reviewer* comentou esses produtos (dois ou mais). Relembrando que, o nível de centralidade aumenta com o número de ligações que o produto possui, isto é, quantas mais vezes o produto fizer parte do conjunto de comentários de um *reviewer*, maior é a sua centralidade.

Através das redes de produtos, é possível identificar a relação entre os vários produtos, assim como a intensidade das mesmas. A consistência da medida de centralidade com o nível de *rating* e de utilidade serão então testadas, de forma a responder às questões de investigação: A pontuação do produto está relacionada com o número de *reviews*? E com a utilidade das mesmas?

As duas questões centrais da investigação serão suportadas através da verificação das seguintes hipóteses de investigação:

H1. Existe alguma relação entre a centralidade da review e o rating do produto;

H2. Existe alguma relação entre a centralidade da review e a sua helpful;

H3. A centralidade da review tem um impacto significativo no rating do produto;

H4. A centralidade da review tem um impacto significativo na sua helpful.

Para testar as hipóteses de investigação formuladas, serão primeiramente, identificados os produtos com maiores níveis de centralidade na rede produzida, com recurso ao programa *Gephi*, possibilitando a análise da relação entre as variáveis em estudo através de uma matriz de correlação e modelos de dependência linear, para testar a H1 e H2.

Para testar a H3 e H4, utilizamos o *software* R. Este programa permitirá a análise dos *clusters* existentes na base de dados (secção 3.2.) e, ainda, a construção de uma árvore de regressão para estudar o impacto da centralidade nas variáveis em estudo. De seguida, apresentamos as técnicas que serão utilizadas para testar as hipóteses em causa.

3.2. Clustering

A análise de *clusters* é um conjunto de técnicas estatísticas que são aplicadas com o objetivo de encontrar agrupamentos naturais ou segmentos nas observações de um conjunto de dados. Esta análise de dados também é conhecida por análise classificatória.

O *cluster* analisa a tendência dos nós mais próximos estarem conectados, isto é, se o nó *a* e *b* estão conectados, e *b* e *c* também estão, então *a* e *c* estão ligados (M. Newman, 2003). Os *clusters* são assim, caracterizados por aproximar os vizinhos, tendo o poder de influenciar os restantes utilizadores, aumentando e concentrando a influência entre os pares.

Os grupos devem ser homogêneos, ou seja, os objetos devem ser semelhantes, e os objetos pertencentes a grupos distintos devem ser diferentes. Existindo assim, duas metodologias de análise de *clusters* mais conhecidas: a análise hierárquica e a análise não-hierárquica.

3.2.1. Análise Hierárquica

Na análise hierárquica é feito um agrupamento ascendente dos *n* indivíduos ou variáveis, começando com *n clusters* até ao número final de grupos. Baseia-se na construção de uma matriz de semelhança ou diferenças, em que cada elemento da matriz descreve o grau de semelhança ou diferença entre cada dois casos, com base nas variáveis escolhidas.

3.2.2. Análise não hierárquica – *K-Means*

É um método que visa a participação de n observações em k *clusters*, em que cada observação pertence ao *cluster* com o centro mais próximo da média. Sendo que, o objetivo é minimizar a soma do erro quadrático dos vários grupos gerados, isto é, quanto menor a soma, mais homogêneos serão os grupos. Este método implica uma escolha prévia do número de pontos iniciais (centroides), originando um número de grupos predefinido pelo analista.

3.3. Base de Dados

Para construir a rede de produtos é necessária uma base de dados que contenha informação sobre os produtos, as *reviews* e os *reviewers* (utilizadores). A base de dados utilizada neste estudo é disponibilizada pela empresa, Amazon.com³ (He & McAuley, 2016). Esta escolha foi considerada adequada, por se tratar de uma empresa pioneira no uso destas ferramentas e onde as *reviews* continuam a ser um fator chave do próprio *site* (McAuley *et al*, 2015).

A base de dados disponível contém mais de 150 milhões de *reviews* em produtos de várias categorias, que vão desde “livros e tecnologia” a “artigos de beleza”, abrangendo avaliações entre maio de 1996 a julho de 2014. De forma a tornar o trabalho exequível, iremos focar o estudo em apenas uma categoria - instrumentos musicais. A seleção desta categoria deve-se ao facto de ser constituída por subcategorias de produtos, com características técnicas, que necessitam de muita pesquisa e consequentemente, as *reviews* são muito úteis.

Atualmente, são 15, as subcategorias existentes na plataforma, entre as quais, guitarras, guitarras baixas, Ukeleles, teclados, microfones, cordas e acessórios, entre outras. Os potenciais compradores leem as experiências e *feedbacks* de outros utilizadores que adquiriram o produto, identificando-se nos comentários publicados. Na categoria – instrumentos musicais, contabilizámos cerca de 10 261 *reviews* e 500 176 *ratings*, o equivalente a 717 produtos e em cada *review* possuímos a informação descrita abaixo:

³ Base de dados: <http://jmcauley.ucsd.edu/data/amazon/>

Tabela 2 - Descrição da base de dados

| | |
|---|---|
| <i>ReviewerID</i> | ID do utilizador (por exemplo, A1RSDE90N6RSZF) |
| Produto ID | ASIN ⁴ |
| <i>Review/Nome do Utilizador</i> | Nome do <i>reviewer</i> |
| <i>Helpful</i> | Fração dos utilizadores que acharam a <i>review</i> útil |
| <i>Review/Texto</i> | Texto da <i>Review</i> |
| <i>Rating</i> | Classificação do produto – métrica apresentada[1(mau);5(muito bom)] |
| Resumo | Resumo da <i>Review</i> |
| <i>Review/Tempo</i> | Data da <i>Review</i> |

Previamente, quando iniciámos o trabalho, existiam cerca de 10 261 *reviews* de produtos (mencionadas acima). No entanto, a amostra efetiva do estudo é de 2 214 *reviews*. O diferencial apresentado resulta da exclusão das *reviews* dos produtos que tinham 0 votos na utilidade, dos erros criados em algumas linhas quando os dados foram transportados para o formato .xlsx, gerando campos “não definidos” e dados inseridos em colunas incorretas e ainda, da omissão das *reviews* com data inferior ao ano de 2010. Estas *reviews* criaram 5 562 relações de 717 produtos distintos, com datas compreendidas entre 2010-2014.

3.4. Software Utilizado

São dois os *softwares* utilizados neste estudo, o R⁵ (Suzuki & Shimodaira, 2006) e o *Gephi*⁶ (Bastian *et al.*, 2009). Para construir a rede de produtos da categoria selecionada, do maior *site* de comércio eletrónico, usamos um programa que utiliza ferramentas baseadas em gráficos para visualização de redes, *Gephi*. Por fim, para a análise de *clusters* e da árvore de regressão utilizou-se o programa R.

⁴ O número de identificação padrão da Amazon (ASIN) é um identificador exclusivo alfanumérico de 10 caracteres atribuídos pela Amazon.com para identificar o produto dentro da organização.

⁵ <http://cran.r-project.org>

⁶ <https://gephi.org/>

3.4.1. *Software Gephi*

O *software*, denominado por *Gephi*, além da visualização gráfica, incorpora na mesma plataforma a extração dos dados e a análise detalhada da rede. É um *software* gratuito (disponível em: <http://gephi.org>), bastante popular e com diversas aplicações na área das ciências sociais (Bastian *et al.*, 2009).

Com a utilização deste programa conseguimos obter informações essenciais para a investigação, tais como a centralidade, a deteção de comunidades de produtos inseridas dentro desta categoria e ainda, a apresentação gráfica da rede de produtos.

Na representação da rede gerada, cada nó representa um produto e cada aresta a ligação entre estes. Isto é, se um *reviewer* comentou vários produtos, então estes ficam ligados, podendo se tratar de produtos similares, complementares, entre outros. A análise destes produtos será elaborada com detalhe, posteriormente, com o resultado da modularidade, onde cada comunidade apresenta uma tonalidade diferente na rede de produtos.

Este passo é produzido por um algoritmo que identifica as comunidades através da relação entre os nós. Paralelamente, foi adicionada uma opção para o tamanho dos nós com base na centralidade, ou seja, quanto maior o grau de centralidade do produto, maior a dimensão do nó na rede.

Em seguida, os dados foram preparados em dois ficheiros distintos com formato .csv, de modo a poderem ser utilizados no *software*. Um primeiro ficheiro para os nós da rede, em que procedemos à identificação e numeração dos nós (produtos). Note-se que, na base de dados disponível, apenas é divulgado o código do produto (ASIN), o que exigiu uma leitura individual de cada linha para obtermos a descrição do produto.

Um segundo ficheiro para a representação da ligação entre os produtos, ou seja, as arestas da rede. Para tal, procedeu-se à identificação da origem e do destino da ligação dos mesmos. Inicialmente as relações dos produtos estavam expressas em “*two mode*” (relação entre o *reviewer* e o produto) e foram transformadas em “*one mode*” (relação entre os produtos).

Por fim, com os resultados gerados pelo *software*, iremos elaborar uma matriz de correlação com as variáveis “centralidade”, “*rating*” e “*helpful*” para verificar as duas primeiras hipóteses

de investigação mencionadas no ponto anterior. Adicionalmente, analisaremos a modularidade dos produtos, outra variável gerada pelo programa *Ghepi*.

3.4.2. *Software R*

O *software R* é uma importante ferramenta de análise de dados utilizada universalmente. O programa pode ser obtido gratuitamente em <http://cran.r-project.org> e é compatível com várias plataformas, como o Windows e o MacOS (Pires, 2017).

O R permite que o utilizador altere funcionalidades existentes e adicione novas, tornando-o versátil e inovador. É alvo de atualizações constantes através da instalação de novos *packages*, transformando-o, desta forma, num importante e poderoso recurso de análise interativa de dados (Souza *et al.*, 2014).

Com a utilização deste programa analisamos os *clusters*, isto é, os subgrupos criados dentro da categoria de produtos observada – instrumentos musicais. Usualmente, estes produtos são substitutos ou complementares. Para tal criamos, um ficheiro em formato .csv, com o valor da centralidade, do *rating* e do *helpful* e inserimos no programa, para procedermos ao cálculo das distâncias entre todos os produtos. Após este cálculo, o programa está pronto para mostrar os resultados dos *clusters*.

Numa segunda fase, instalámos o *package* “*rpart*”, usado para obter árvores de regressão. Gerámos uma árvore de regressão que respondem às restantes hipóteses de investigação, H3 e H4. Para a H3, o ficheiro .csv apresenta dados da centralidade *eigenvector* e do *rating*, e para responder a H4, o ficheiro .csv continha dados sobre a centralidade *eigenvector* e a *helpful*. Os resultados gerados por ambos os *softwares*, serão apresentados no próximo ponto.

4. Resultados

Nesta fase, é feita uma descrição detalhada das análises realizadas às variáveis em estudo e, em seguida, são apresentados os resultados dos testes efetuados, que permitem verificar a relação entre a centralidade das *reviews* e as classificações dos produtos e ainda, com a utilidade associada às *reviews*.

4.1. Análise da Centralidade

A obtenção dos resultados da centralidade dos produtos advém de uma opção fornecida pelo programa *Gephi*. Para a análise desta medida, procedeu-se ao cálculo de duas centralidades: a centralidade de intermediação (*betweenness centrality*) e a centralidade *eigenvector* (vetor próprio). A primeira por se tratar da medida mais utilizada (Wasserman & Faust, 1994) e, a segunda por se revelar na medida mais adequada, uma vez que considera para o cálculo, tanto a centralidade dos vizinhos, como a qualidade dos mesmos (Bonacich, 2007).

No programa, antes de obter os resultados, especificamos algumas propriedades para a representação da rede. O tamanho dos nós compreendidos entre 15 e 80 com base na centralidade, ou seja, os nós menos centrais possuirão um tamanho mais reduzido e os restantes, um tamanho superior (como podemos verificar na representação gráfica abaixo). Por fim, inserimos diferentes cores para cada comunidade encontrada, através do cálculo da modularidade.




Figura 1 - Rede de Produtos da categoria Instrumentos Musicais

A rede não apresenta os triângulos, ou seja, o autor das *reviews* que avaliou produtos que não foram avaliados por outro *reviewer*, não estabelecerá relações com outros utilizadores. Isto foi possível com o filtro fornecido pelo programa que apenas considerou as ligações superiores a 2 nós.

O programa detetou as comunidades existentes na rede de produtos, sendo que inicialmente, cada nó representava uma comunidade (717 comunidades), e numa segunda fase, os nós são movidos para a comunidade onde obtiver maiores ganhos, gerando, no final, 30 comunidades. O maior grupo de nós está representado pela cor lilás, com uma percentagem de 10.74. De seguida, temos o grupo verde, detentor de 9.76%, ocupando assim o terceiro lugar, a cor azul com uma percentagem de 9.07. As restantes cores ocupam uma percentagem

no intervalo 7%-8%, à exceção da cor cinza, que detém as restantes comunidades que apenas suportam uma percentagem inferior a 7%.

De acordo com a Figura 2, o nó com tamanho superior (representado com uma cor rosa) apresenta um valor de centralidade (centralidade de intermediação) de 31 506, quer isto dizer que na rede, o produto produz 31 506 ligações, de um total de 1 369 436. Isto significa que, este produto cruza-se 31 506 vezes com os restantes produtos. No segundo lugar, de cor verde, corresponde um nó com cerca de 30 049 ligações.

4.2. Análise dos *Clusters*

Na análise de redes, torna-se relevante detetar subgrupos de nós, uma vez que, enquanto o grau da rede relaciona-se com a conectividade da mesma, o *clustering* relaciona-se com a consistência de determinados padrões. Um *cluster* é um subgrupo de nós onde os produtos são muito idênticos entre si, e distintos para com os restantes *clusters* de produtos. Um *cluster* mais alto aumenta a redundância, o que torna cada laço menos importante e compromete a concisão da rede (Muller & Peres, 2018).

A metodologia utilizada foi a análise não hierárquica – *K-means*, pelo que, seleccionamos cinco centroides (pontos iniciais), pois, note-se que a Amazon usa uma hierarquia de categorias para classificar os instrumentos musicais. Depois de seleccionados os cinco pontos como sendo os centroides iniciais, o programa repete o algoritmo até atingir o mínimo do critério estabelecido: a) formar 5 *clusters*, associando cada novo produto ao centroide mais próximo; b) recalculando o centroide de cada *cluster*.

Através do *software* R, e da função *rpart* inserimos três variáveis: centralidade, *rating* e *helpful*, com a parametrização para cinco *clusters*. A cada *cluster* está associado um número de produtos homogêneos ao centroide estabelecido pelo algoritmo (Tabela 3). O primeiro grupo apresenta um conjunto de 266 produtos, o segundo de 193, e os restantes, de 155, 22 e 81, respetivamente.

Tabela 3 - Análise de *clusters*

| <i>Cluster</i> | <i>Centralidade</i> | <i>Rating</i> | <i>Helpful</i> | <i>Dimensão</i> |
|----------------|---------------------|---------------|----------------|-----------------|
| 1 | 0.069 | 4.989 | 0.922 | 266 |
| 2 | 0.124 | 4.539 | 0.913 | 193 |
| 3 | 0.111 | 3.997 | 0.857 | 155 |
| 4 | 0.049 | 1.515 | 0.721 | 22 |
| 5 | 0.088 | 3.189 | 0.794 | 81 |

O *Cluster* 1, detentor de 266 produtos possui o *rating* mais elevado, bem como a *helpful*, e por sua vez, uma das centralidades mais reduzidas. Trata-se de produtos compreendidos num intervalo de *rating* entre [4.777, 5]. É constituído por produtos relativos a cabos, sintonizadores e pedais, e segundo os resultados encontrados, são estes produtos que os utilizadores menos comentam, mas que por sua vez, possuem classificações altas.

O *Cluster* 2, com 193 produtos é caracterizado por microfones, cabos e acessórios. Como no *cluster* anterior, estes produtos possuem *ratings* elevados, e ao mesmo tempo, a maior centralidade, a par da *helpful*. Em termos práticos, os produtos destes *clusters*, são os que mais cativam a atenção dos utilizadores no *site* da Amazon.com, fazendo com que estes partilhem a sua opinião de forma espontânea, que classifiquem o produto e que, ainda, qualifiquem a utilidade das *reviews* no processo de tomada de decisão. Estes produtos encontram-se então, no centro da rede dos produtos.

O *Cluster* 3 possui a segunda maior centralidade, auxiliado de um *rating* médio, assim como a *helpful*. Os produtos que fazem parte integrante deste *cluster* são direcionados para cordas e suporte de guitarra. Notando que alguns produtos do *cluster* 1, também estão inseridos neste, o que podemos concluir aqui é que, estão aqui inseridos os produtos caracterizados por altos níveis de centralidade que não podiam ser incluídos no primeiro, por não ser uma propriedade do mesmo.

O próximo *Cluster*, o 4, é formado por 22 produtos, representando assim, o *cluster* de menor dimensão. Trata-se de uma rede muito concisa e com laços muito fortes. É, essencialmente, constituído pelos produtos com as classificações mais reduzidas de todas as variáveis, que integram acessórios para as cordas e outros acessórios diversos, ou seja, os produtos são muito idênticos entre si. Podemos afirmar que, as propriedades deste subgrupo são opostas

às do *cluster* 2, pois são estes os produtos que menos cativam a atenção dos utilizadores. Na representação geográfica, são estes que estão na parte exterior da rede (poucas interligações entre os produtos).

Por fim, o *Cluster* 5 é constituído por 81 produtos à base de amplificadores, cabos, acessórios e inclui ainda, um Ukelele⁷. Este último produto é o que diferencia este subgrupo do primeiro. Os produtos revelam um *rating* intermédio, mas uma *helpful* e centralidade reduzida. Os utilizadores que estão associados a estes produtos são apreciadores de música, inclusive, partilham o gosto em comum do instrumento havaiano.

Em suma, como se trata de centroides de uma categoria específica de produtos, os vizinhos mais distantes de cada *cluster* já apresentam mais semelhanças com produtos dos restantes *clusters*, uma vez que, como mencionado anteriormente, um *cluster* mais alto aumenta a redundância, o que torna cada laço menos importante e compromete a concisão da rede. Note-se que se trata de uma categoria de produtos específica, em que o critério de dissemelhança pode ser dado pela marca do produto, por esta potenciar maiores níveis de confiança.

4.3. Teste das Hipóteses de Investigação

Esta investigação visa analisar a relação entre a classificação do produto, o número de *reviews* e a sua utilidade. Pretendemos responder à seguinte questão: A pontuação do produto está relacionada com o número de *reviews*? E com a utilidade das mesmas? Estas questões serão suportadas por quatro testes de hipóteses. Inicialmente, com o recurso da rede de produtos obtemos o resultado de duas hipóteses de investigação, e numa fase mais avançada, com o recurso a uma árvore de regressão, damos resposta às restantes hipóteses.

Inicialmente, para tornar exequível a análise relação entre as variáveis acima mencionadas, recorreremos ao cálculo da média do *rating* e do *helpful* para cada produto, uma vez que em vários casos, o mesmo produto possuía vários comentários de utilizadores distintos, que apresentavam taxas de *helpful* diferenciadas, assim como para os valores do *rating*.

A análise da correlação tem por objetivo medir o grau de relação entre variáveis e indica até que ponto os valores de uma variável estão relacionados com os de outra. O valor será dado

⁷ Ukelele – Instrumento musical havaiano com cordas beliscadas. Descrito como muito versátil.

pelo coeficiente de correlação que traduz o tipo de relação entre estas, se é forte ou fraca, se possui relação positiva ou negativa. Seguidamente, apresenta-se na tabela seguinte, as relações existentes entre as variáveis em estudo, com base na matriz de correlação.

Tabela 4 - Matriz de correlação

| | <i>Helpful</i> | <i>Rating</i> | <i>Centralidade</i> |
|---------------------|----------------|---------------|---------------------|
| <i>Helpful</i> | 1.000 | | |
| <i>Rating</i> | 0.350 | 1.000 | |
| <i>Centralidade</i> | 0.048 | 0.013 | 1.000 |

4.3.1. Relação entre a centralidade e o *rating* do produto

Segundo os resultados apresentados na Tabela 4, a centralidade e o *rating* apresentam uma correlação baixa. Em termos práticos este valor indica-nos que as variáveis *rating* e centralidade não estão correlacionadas. Através do auxílio do diagrama de dispersão (Figura 3) verifica-se que este não apresenta uma forma definida e ainda, em alguns pontos a variável centralidade assume um valor constante. Examinando uma relação de dependência entre centralidade e *rating*, a capacidade explicativa do *rating* na centralidade é muito baixa, como se pode ver pelo valor de R^2 ($R^2=0.0002$ – Figura 3).

Conforme exposto na fase exploratória da literatura, a existência de uma relação fraca entre o número de *reviews* e a sua classificação revela que o utilizador publica *reviews*, quer o produto seja bom (*rating* alto) ou mau (*rating* baixo). Os produtos centrais são os produtos mais mediáticos, os que captam mais atenção dos utilizadores e os que detêm mais comentários sobre a sua *performance*. Contudo, o que se revela é que mais *reviews* (maior centralidade) não são sinónimo de melhor qualidade, isto é, o produto pode ser central na rede, mas ser portador de uma classificação baixa.




Figura 2 - Análise de dispersão entre *eigencentrality* e o *rating*

Desta forma, torna-se crucial que as empresas de comércio eletrónico dediquem igual atenção a ambas as variáveis de forma individualizada, uma vez que, os utilizadores que classificam o produto podem escrever apenas os aspetos negativos do produto, enquanto outros atribuem classificação máxima no *rating*. Outra justificação passa pela confiança do utilizador, isto é, na forma em que se sente mais confortável para partilhar a sua opinião com os restantes membros, considerando assim, que existem “sub-categorias” de *reviewers* – os que escrevem, os que pontuam e os que avaliam o que foi escrito.

4.3.2. Relação entre a centralidade da *review* e a sua *helpful*

Relativamente aos resultados da análise da relação entre a centralidade das *reviews* e a utilidade das mesmas que constam no produto, verificamos que, apesar de apresentarem um valor superior aos resultados da análise anterior, esta relação ainda possui um valor baixo (Figura 4). Isto é, um aumento da taxa da *helpful* aumenta, ligeiramente, o valor da centralidade. O mesmo comportamento para o cenário inverso, isto é, uma diminuição na utilidade, proporcionará diminuições no valor da centralidade.

Este resultado traduz o efeito positivo das *reviews* úteis, isto é, quando um produto é detentor de *reviews* úteis, a tendência é que o número de *reviews* no produto aumente. Relembrando que a *helpful* de uma *review* revela o diagnóstico, isto significa, a capacidade para outros consumidores compreenderem melhor a qualidade e o desempenho do produto ou serviço.

Como se expôs na revisão de literatura, a questão: “*Esta review foi útil?*” tem tomado um papel cada vez mais importante no auxílio da tomada de decisão do consumidor, o que faz com que o utilizador receba informação de alguém que já utilizou o produto e decidiu partilhar a sua experiência de forma espontânea e gratuita. No entanto, o produto pode apresentar taxas elevadas de centralidade (elevado número de comentários), mas expor *reviews* pouco úteis para os utilizadores. Note-se que, na base de dados em estudo, quase todos os produtos apresentam elevadas taxas de utilidade, o que revela, que contribuíram de forma positiva para o aumento da centralidade, conforme demonstrado na Tabela 3




Figura 3 - Análise de dispersão entre a centralidade e o *helpful*

Adicionalmente, com base na matriz de correlação (tabela 4) podemos observar que a correlação mais elevada, não é entre a centralidade e as outras variáveis, mas sim entre o *rating* e a *helpful* da *review* (+0.35). Esta correlação positiva é ligeiramente alta, mas muito superior às correlações observadas com as restantes variáveis. Este resultado permite demonstrar que um produto com um *rating* elevado, usualmente possui *reviews* que auxiliaram os utilizadores.

4.3.3. Impacto da centralidade da *review* no *rating*

As árvores de apoio à decisão são cada vez mais utilizadas nos dias de hoje com o intuito de tornar as escolhas mais eficientes. São construídas a partir de aprendizagem matemática, onde se destacam os algoritmos supervisionados e os algoritmos não supervisionados. Para

responder à terceira hipótese de investigação, desenvolvemos uma árvore de regressão – a decisão a tomar é numérica (i.e. o valor do *rating*), utilizando o programa R.

Pretende-se com esta análise, prever o impacto da centralidade das *reviews* nas restantes variáveis. Numa primeira fase, lemos o ficheiro e colocamos os dados no data.frame “dados”, de seguida, adicionamos o *package* “rpart” – que estava localizado numa livraria de funções e, por último, gerámos uma árvore de regressão para a variável “centralidade” utilizando as restantes variáveis.

```
> dados <-  
(read.table("C:/Users/Sonia/Desktop/Newfolder/Livro1.csv",sep=";",dec=".",header=TRUE))  
> library(rpart)
```

Figura 4 - Comandos utilizados para obter a árvore de regressão

Seguidamente, apresentamos os resultados do modelo na figura 5.

```

> arv.regr
node), split, n, deviance, yval
  * denotes terminal node

n= 717
1) root 717 11.6779100 0.09431841
2) Rating >= 4.954545 249 2.1051380 0.06585635 *
3) Rating < 4.954545 468 9.2637340 0.10946170
6) Rating < 4.038462 229 2.9235220 0.08156874
12) Rating < 3.366667 71 0.4298500 0.05181858 *
13) Rating >= 3.366667 158 2.4025940 0.09493749
26) Rating >= 3.895833 101 0.5629613 0.06234909 *
27) Rating < 3.895833 57 1.5423090 0.15268180 *
7) Rating >= 4.038462 239 5.9913350 0.13618760
14) Rating >= 4.190909 229 4.8743080 0.12741650
28) Helpful >= 0.9986111 84 1.0635350 0.10078320 *
29) Helpful < 0.9986111 145 3.7166720 0.14284540
58) Helpful < 0.9194444 99 1.4758920 0.11643640
116) Rating < 4.690476 83 0.8661336 0.10100760 *
117) Rating >= 4.690476 16 0.4875061 0.19647330 *
59) Helpful >= 0.9194444 46 2.0231340 0.19968220
118) Rating >= 4.619048 23 0.2049778 0.13850140 *
119) Rating < 4.619048 23 1.6459730 0.26086310 *
15) Rating < 4.190909 10 0.6959700 0.33704570 *

```

Figura 5 – Regras obtidas a partir da árvore de regressão

(*) - representa os nós que estão nos ramos finais da árvore

Na figura anterior, a primeira linha indica-nos que estão presentes 717 produtos na categoria “Instrumentos Musicais”, e nas seguintes linhas estão as informações sobre cada nó. Por exemplo, no nó número 2, encontram-se 249 produtos que possuem um *rating*, superior ou igual a 4.95. Ainda, a soma dos quadrados dos desvios em relação à média, na variável objetivo – centralidade, é de 2.10, para os casos em que o *rating* é ≥ 4.95 . Por fim, o último valor, 0.066 (aproximadamente), é o valor médio da centralidade, dos exemplos em que o *rating* é maior ou igual a 4.95.

Na última linha, no nó 15, lemos que, quando o *rating* é inferior a 4.19, o valor médio da centralidade, é, aproximadamente, 0.34. Na imagem abaixo (Figura 6), apresentamos a árvore de regressão gerada pelo programa.

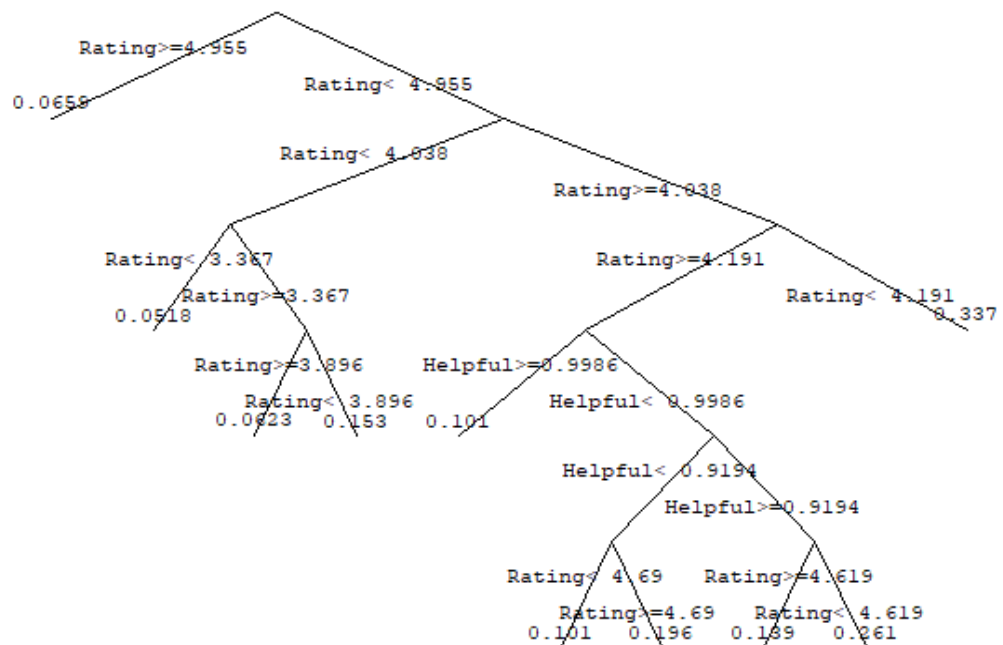


Figura 6- Árvore de regressão

Para avaliar o comportamento do *rating* na centralidade, pela árvore, lemos que, para um qualquer caso em que o *rating* é superior a 4.95, a centralidade possui um valor igual a 0.066. Lê-se também que, se o *rating* é maior que 4.191, com a *helpful* menor que 0.99, e o *rating* inferior a 4.69, a centralidade é de 0.10, senão, centralidade = 0.196 (para os casos em que o *rating* é superior a 4.69).

Quando o *rating* assume o valor mais reduzido apresentado na árvore (*rating* = 4.191), a centralidade assume o valor mais elevado (centralidade = 0.33). Desta forma, podemos concluir que a centralidade tem um impacto negativo no *rating*, uma vez que os resultados demonstram que quando o *rating* apresenta o valor mais alto, a centralidade apresenta o valor

mais reduzido. Realce-se que, estamos perante valores elevados de *rating*, pois estão apenas compreendidos entre [4,5].

4.3.4. Impacto da centralidade da *review* na *helpful*

Fazendo uso da árvore de regressão apresentada anteriormente, para responder à última hipótese de investigação, lemos que, quando o *rating* está entre 4.955 e 4.191, e a *helpful* é superior a 0.9986, a centralidade é de 0.10. Quando a *helpful* é de 0.9194, com um *rating* inferior a 4.619, a centralidade é de 0.261. As leituras possíveis nos ramos da árvore de regressão, interpretam-se no mesmo sentido, revelando desta forma, um impacto positivo entre a centralidade e a *helpful*.

Na análise entre a centralidade e a *helpful*, deparamo-nos com uma maior correlação entre a centralidade das *reviews*, com a *helpful* das mesmas, uma vez que, valores elevados da *helpful*, estão associados a aumentos graduais da centralidade. Quando o produto possui *reviews* úteis, a tendência é que o número de *reviews* aumente. Verifica-se ainda, concordância com os resultados encontrados na hipótese de investigação 2, aquando da análise da correlação entre ambas as variáveis.

Em suma, os resultados entre a hipótese 2 e a hipótese 4 são concordantes. Isto é, quanto mais úteis são as *reviews*, maior o número de *reviews* no produto. Apresentando assim, uma relação positiva entre estas. No que concerne, às restantes hipóteses, estas não suportam a associação realizada *à priori* – produtos portadores de melhores classificações, são os que possuem mais comentários.

Após a verificação das hipóteses de investigação, estamos aptos para responder às questões centrais:

1. A pontuação do produto está relacionada com o número de *reviews*? Os nossos resultados apresentam evidências significativas de que não há uma relação clara entre o aumento do *rating* do produto e o número de *reviews*. Isto é, conclui-se que os consumidores comentam um produto, independentemente da sua qualidade. Logo, um elevado número de *reviews*, não implica um produto com boa classificação.

2. E com a utilidade das mesmas? Os resultados indicam que quando os *reviews* são úteis para a tomada de decisão dos consumidores, a tendência é que o número de *reviews* aumente.

5. Conclusão, Limitações e Sugestões para trabalhos futuros

Vivemos numa era de informação que prevê um nível de acesso sem precedentes para todos os dados eletrónicos, produtos e serviços. Todavia, muitas vezes escolher o “certo” é uma tarefa exigente para os consumidores (Hennig-Thurau *et al.*, 2012). Ao longo destes últimos anos, novas funcionalidades surgiram, tornando a compra *online* uma operação mais proativa, inteligente e personalizada. Desta forma, o objetivo desta área de negócio é atender às necessidades dos utilizadores numa variedade de domínios, por exemplo, que produto comprar (Amazon.com), que música ouvir (Spotify), em que hotel ficar (TripAdvisor).

Este estudo deu resposta a duas questões de investigação: (1) A pontuação do produto está relacionada com o número de *reviews*? (2) E com a utilidade das mesmas? Para dar suporte a estas questões, foram formuladas e testadas quatro hipóteses de investigação, com base em dados de *reviews* de produtos da Amazon.com.

Verificou-se que um número elevado de *reviews* (maior centralidade) não é sinónimo de melhor qualidade, isto é, o produto pode ser central na rede, mas ser portador de uma classificação baixa. Conforme discutido na revisão da literatura, a existência de uma relação fraca entre o número de *reviews* e a sua classificação revela que o utilizador publica *reviews*, quer o produto seja bom (*rating* alto) ou mau (*rating* baixo).

Ao testar a 2ª hipótese de investigação descobrimos que um aumento da taxa da *helpful* aumenta, ligeiramente, o valor da centralidade. A questão: “*Esta review foi útil?*” tem tomado um papel cada vez mais importante no auxílio da tomada de decisão do consumidor, o que faz com que este receba informação de alguém que já utilizou o produto e decidiu partilhar a sua experiência. Note-se que, na base de dados em estudo, quase todos os produtos apresentam elevadas taxas de utilidade, o que sugere, que contribuíram de forma positiva para o aumento da centralidade – este ciclo de positividade da utilidade (*review* favorável cria aumento na taxa da utilidade), reforça os resultados do estudo de Chua & Banerjee (2016). Os autores, descobriram que a relação entre a qualidade da informação e a utilidade da *review* varia em função do produto e da *review* (favorável, desfavorável e misto).

Os resultados deste estudo contribuem para a literatura sobre *reviews*, preenchendo uma lacuna existente até então, uma vez que pouco se sabia sobre a relação entre classificação do produto, utilidade da *review* e o número de *reviews*. Coopera com novas descobertas

relativamente aos estudos existentes sobre *reviews* e sobre a *helpful* (Chua & Banerjee, 2016; Ghose & Ipeirotis, 2011; S. Park & Nicolau, 2015), acrescentando informação relevante sobre como se relacionam estas variáveis com o *rating* do produto.

Ainda, a nossa investigação ilustra como os dados revelados pelas redes *online* podem ser usados para definir e responder a novos tipos de pesquisa e fornece novas evidências empíricas sobre o impacto da centralidade das *reviews* no *rating* e na *review*. Sublinhando-se como principal conclusão, que a quantidade de *reviews* não está fortemente relacionada com a classificação do produto (*rating*) e com a utilidade das mesmas (*helpful*). Este resultado permite sugerir que produtos mais populares não estão associados a *ratings* ou utilidade da *review* mais elevados.

Com base nas conclusões do estudo, podem-se sugerir os seguintes contributos para a gestão das empresas com modelos de *e-Commerce*: torna-se crucial que as empresas de comércio eletrónico dediquem igual atenção às 3 componentes (*rating*, *review* e *helpful*) de forma individualizada, uma vez que, os utilizadores que classificam o produto podem escrever apenas os aspetos negativos do produto, enquanto outros atribuem classificação máxima no *rating*. Outra sugestão passa pela análise da confiança do utilizador, isto é, na forma em que se sente mais confortável para partilhar a sua opinião com os restantes membros, considerando assim, que existem “sub-categorias” de *reviewers* – os que escrevem, os que pontuam e os que avaliam o que foi escrito.

Embora esta investigação se revele mais um passo na análise das *reviews*, reconhecemos que a abordagem utilizada tem limitações, sendo a principal, a análise única de uma categoria de produtos específica e não o *rol* de produtos disponíveis no *Marketplace* da Amazon, sendo que as conclusões recolhidas neste estudo, apenas se aplicam à categoria de produtos escolhida. Por conseguinte, como sugestão para trabalhos futuros, sugere-se que se analise uma diferente categoria de produtos (livros, por exemplo), para verificar se esta apresenta resultados semelhantes àqueles que obtivemos.

Outra limitação presente, é que as conclusões recolhidas neste estudo também estão afetadas apenas a um *Marketplace* e a um intervalo de tempo, sendo 2014 o ano mais recente na base de dados. Deste modo, surge uma segunda sugestão: a análise da relação das variáveis quando novos dados forem disponibilizados, com o intuito de verificar se os resultados serão semelhantes.

Referências Bibliográficas

- Adomavicius, G., & Kwon, Y. (2012). Improving Aggregate Recommendation Diversity Using Ranking-Based Techniques. *IEEE Transactions on Knowledge and Data Engineering*, 24(5), 896–911. <https://doi.org/10.1109/TKDE.2011.15>
- Adomavicius, G., & Tuzhilin, A. (2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749. <https://doi.org/10.1109/TKDE.2005.99>
- Ahmed, A., Kanagal, B., Pandey, S., Josifovski, V., Pueyo, L. G., & Yuan, J. (2013). Latent factor models with additive and hierarchically-smoothed user preferences. *Proceedings of the Sixth ACM International Conference on Web Search and Data Mining - WSDM '13*, 385. <https://doi.org/10.1145/2433396.2433445>
- Anderson, M., & Magruder, J. (2012). Learning from the Cloud: Regression Discontinuity Estimates of the Effects of an Online Review Database. *The Economic Journal*, 122(October), 957–989. <https://doi.org/10.1111/j.1468-0297.2012.02512.x>
- Audun, J., Roslan, I., & Boyd, C. a. (2007). A Survey of Trust and Reputation Systems for Online Service Provision. *Decision Support Systems*, 43(2), 618–644. <https://doi.org/10.1016/j.dss.2005.05.019>
- Barabási, A.-L. (2014). Network Science. *Network Science*, 1–27. <https://doi.org/10.1007/978-1-4614-6744-1>
- Bartosiak, M. L., & Piccoli, G. (2016). Presentation Format and Online Reviews Persuasiveness: The Effect of Computer- Synthesized Speech. *2016 International Conference on Information Systems, ICIS 2016*, 1–11.
- Basilico, J., & Hofmann, T. (2004). A Joint Framework for Collaborative and Content Filtering. *Proceedings of the 27th Annual International Conference on Research and Development in Information Retrieval - SIGIR '04*, 550. <https://doi.org/10.1145/1008992.1009115>
- Bastian, M., Heymann, S., & Jacomy, M. (2009). Gephi: An Open Source Software for Exploring and Manipulating Networks. *Third International AAAI Conference on Weblogs and Social Media*, 361–362. <https://doi.org/10.1136/qshc.2004.010033>
- Billsus, D., & Pazzani, M. J. (1998). Learning Collaborative Information Filters Daniel. *Proceedings of the Fifteenth International Conference on Machine Learning*, 54, 47. Retrieved from <http://www.aaai.org/Papers/Workshops/1998/WS-98-08/WS98-08-005.pdf>

- Bodapati, A. V. (2008). Recommendation Systems with Purchase Data. *Journal of Marketing Research (JMR)*, 45(1), 77–93. <https://doi.org/10.1509/jmkr.45.1.77>
- Bonacich, P. (2007). Some unique properties of eigenvector centrality. *Social Networks*, 29(4), 555–564. <https://doi.org/10.1016/j.socnet.2007.04.002>
- Bonchi, F., Castillo, C., Gionis, A., & Jaimes, A. (2011). Social Network Analysis and Mining for Business Applications. *ACM Transactions on Intelligent Systems and Technology*, 2(3), 1–37. <https://doi.org/10.1145/1961189.1961194>
- Breese, J. S., Heckerman, D., & Kadie, C. (1998). Empirical Analysis of Predictive Algorithms for Collaborative Filtering. *Proceedings of the 14th Annual Conference on Uncertainty in Artificial Intelligence*, 43–52. <https://doi.org/10.1111/j.1553-2712.2011.01172.x>
- Bulte, C., & Stremersch, S. (2004). Social Contagion and Income Heterogeneity in New Product Diffusion: A Meta-Analytic Test. *Marketing Science*, 23(4), 530–544. <https://doi.org/10.1287/mksc.1040.0054>
- Burke, R. (2002). Hybrid Recommender Systems : Survey and Experiments. *Kluwer Academic Publishers*, 12(4), 331–370. <https://doi.org/10.1023/A:1021240730564>
- Burton, J., & Khammash, M. (2013). Why do people read reviews posted on consumer-opinion portals? *Journal of Marketing Management*, 1376, 51–76. <https://doi.org/10.4324/9780203722381>
- Canny, J. (2002). Collaborative Filtering with Privacy via Factor Analysis. *SIGIR'02*, (ACM 1-58113-561-0/02/0008), 11–15.
- Centeno, R., Fresno, V., & Chaquet, J. (2018). From textual reviews to Individual Reputation Rankings: Leaving ratings aside solving MPC task. *Expert Systems with Applications*, 114, 1–14. <https://doi.org/10.1016/j.eswa.2018.07.037>
- Chakravarty, A., Liu, Y., & Mazumdar, T. (2010). The Differential Effects of Online Word-of-Mouth and Critics' Reviews on Pre-release Movie Evaluation. *Journal of Interactive Marketing*, 24(3), 185–197. <https://doi.org/10.1016/j.intmar.2010.04.001>
- Chen, J., Teng, L., Yu, Y., & Yu, X. (2016). The effect of online information sources on purchase intentions between consumers with high and low susceptibility to informational influence. *Journal of Business Research*, 69(2), 467–475. <https://doi.org/10.1016/j.jbusres.2015.05.003>
- Chen, L.-S., Hsu, F.-H., Chen, M.-C., & Hsu, Y.-C. (2008). Developing recommender systems with the consideration of product profitability for sellers. *Information Sciences*,

- 178(4), 1032–1048. <https://doi.org/10.1016/j.ins.2007.09.027>
- Chen, L., Chen, G., & Wang, F. (2015). Recommender systems based on user reviews: the state of the art. *User Modeling and User-Adapted Interaction*, 25(2), 99–154. <https://doi.org/10.1007/s11257-015-9155-5>
- Chen, L., & Wang, F. (2013). Preference-based clustering reviews for augmenting e-commerce recommendation. *Knowledge-Based Systems*, 50, 44–59. <https://doi.org/10.1016/j.knosys.2013.05.006>
- Chua, A., & Banerjee, S. (2016). Helpfulness of user-generated reviews as a function of review sentiment, product type and information quality. *Computers in Human Behavior*, 54, 547–554. <https://doi.org/10.1016/j.chb.2015.08.057>
- Cui, G., Lui, H.-K., & Guo, X. (2012). The Effect of Online Consumer Reviews on New Product Sales. *International Journal of Electronic Commerce*, 17(1), 39–58. <https://doi.org/10.2753/JEC1086-4415170102>
- Das, K., Samanta, S., & Pal, M. (2018). Study on centrality measures in social networks: a survey. *Social Network Analysis and Mining*, 8(1). <https://doi.org/10.1007/s13278-018-0493-2>
- Duan, W., Gu, B., & Whinston, A. B. (2008). Do online reviews matter? - An empirical investigation of panel data. *Decision Support Systems*, 45(4), 1007–1016. <https://doi.org/10.1016/j.dss.2008.04.001>
- eMarketer. (2018). Worldwide Retail and Ecommerce Sales: eMarketer's Updated Forecast and New Mcommerce Estimates for 2016—2021. Retrieved March 12, 2018, from <https://www.emarketer.com/Report/Worldwide-Retail-Ecommerce-Sales-eMarketers-Updated-Forecast-New-Mcommerce-Estimates-20162021/2002182>
- Esparza, S., O'Mahony, M., & Smyth, B. (2011). A Multi-Criteria Evaluation of a User-Generated Content Based Recommender System. *Research Repository UCD*.
- Everett, M., & Valente, T. (2016). Bridging, brokerage and betweenness. *Soc Networks*, 44, 202–208. <https://doi.org/10.1177/0003122413519445>.Are
- Felden, C., & Chamoni, P. (2007). Recommender Systems Based on an Active Data Warehouse with Text Documents. *IEEE Computer Society*, 1–10. <https://doi.org/10.1109/HICSS.2007.460>
- Filieri, R. (2016). What makes an online consumer review trustworthy? *Annals of Tourism Research*, 58, 46–64. <https://doi.org/10.1016/j.annals.2015.12.019>
- Fleder, D., & Hosanagar, K. (2009). Blockbuster Culture's Next Rise or Fall: The Impact of

- Recommender Systems on Sales Diversity. *Management Science*, 55(5), 697–712.
<https://doi.org/10.1287/mnsc.1080.0974>
- Freeman, L. (1978). Centrality in Social Networks Conceptual Clarification. *Social Networks*, 1(3), 215–239. [https://doi.org/10.1016/0378-8733\(78\)90021-7](https://doi.org/10.1016/0378-8733(78)90021-7)
- Gerani, S., Mehdad, Y., Carenini, G., Ng, R., & Nejat, B. (2014). Abstractive Summarization of Product Reviews Using Discourse Structure. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*, 1602–1613.
https://doi.org/10.1007/978-3-642-14834-7_15
- Ghose, A., & Ipeirotis, P. (2011). Estimating the Helpfulness and Economic Impact of Product Reviews: Mining Text and Reviewer Characteristics. *IEEE Transactions on Knowledge and Data Engineering*, 23(10), 1498–1512.
<https://doi.org/10.1109/TKDE.2010.188>
- Goldberg, D., Nichols, D., Oki, B., & Terry, D. (1992). Using Collaborative Filtering to Weave an Information Tapestry. *Communications of the ACM*, 35, 61–70.
- Gomez-Urbe, C., & Hunt, N. (2015). The Netflix Recommender System: Algorithms, Business Value, and Innovation. *ACM Transactions on Management Information Systems*, 6(4), 1–19. <https://doi.org/10.1145/2843948>
- Gössling, S., Hall, C., & Andersson, A.-C. (2018). The manager's dilemma: a conceptualization of online review manipulation strategies. *Current Issues in Tourism*, 21(5), 484–503. <https://doi.org/10.1080/13683500.2015.1127337>
- Ha, T., & Lee, S. (2017). Item-network-based collaborative filtering: A personalized recommendation method based on a user's item network. *Information Processing and Management*, 53(5), 1171–1184. <https://doi.org/10.1016/j.ipm.2017.05.003>
- Hanneman, R., & Riddle, M. (2005). Introduction to Social Network Methods. *Riverside, CA: University of California, Riverside. On-Line Textbook*, 46(7), 5128–30.
<https://doi.org/10.1016/j.socnet.2006.08.002>
- He, R., & McAuley, J. (2016). Ups and Downs: Modeling the Visual Evolution of Fashion Trends with One-Class Collaborative Filtering.
<https://doi.org/10.1145/2872427.2883037>
- Hennig-Thurau, T., Marchand, A., & Marx, P. (2012). Can Automated Group Recommender Systems Help Consumers Make Better Choices? *Journal of Marketing*, 76(5), 89–109.
<https://doi.org/10.1509/jm.10.0537>
- Hennig-Thurau, T., Walsh, G., & Walsh, G. (2003). Electronic Word-of-Mouth: Motives for

- and Consequences of Reading Customer Articulations on the Internet. ... *Journal of Electronic Commerce*, 8(2), 51–74. <https://doi.org/10.1504/IJECRM.2008.020411>
- Hong, S., & Park, H. (2012). Computer-mediated persuasion in online reviews: Statistical versus narrative evidence. *Computers in Human Behavior*, 28(3), 906–919. <https://doi.org/10.1016/j.chb.2011.12.011>
- Hu, N., Bose, I., Gao, Y., & Liu, L. (2011). Manipulation in digital word-of-mouth: A reality check for book reviews. *Decision Support Systems*, 50(3), 627–635. <https://doi.org/10.1016/j.dss.2010.08.013>
- Jackson, M. (2008). Social and Economic Networks 1. *Network*, (March), 14–16. <https://doi.org/10.1017/CBO9781107415324.004>
- Jiang, Z., & Benbasat, I. (2007). Investigating the Influence of the Functional Mechanisms of Online Product Presentations. *Information System Research*, 18(2), 1–17. <https://doi.org/10.1287/isre.1070.0124>
- Kabbur, S., Ning, X., & Karypis, G. (2013). FISM : Factored Item Similarity Models for Top-N Recommender Systems. *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 659–667. <https://doi.org/10.1145/2487575.2487589>
- Kim, H., Ghiasi, B., Spear, M., Laskowski, M., & Li, J. (2017). Online serendipity: The case for curated recommender systems. *Business Horizons*, 60(5), 613–620. <https://doi.org/10.1016/j.bushor.2017.05.005>
- Kong, D., Tang, J., Zhu, Z., Cheng, J., & Zhao, Y. (2017). De-biased dart ensemble model for personalized recommendation. *Proceedings - IEEE International Conference on Multimedia and Expo*, 0, 553–558. <https://doi.org/10.1109/ICME.2017.8019536>
- Koren, Y. (2009). Collaborative Filtering with Temporal Dynamics. *Knowledge Discovery and Data Mining {KDD}*, 447–456. <https://doi.org/10.1145/1557019.1557072>
- Lah, N., Hussin, A., & Dahlan, H. (2017). A Concept-Level Approach in Analyzing Review Readership for E-Commerce Persuasive Recommendation, (978–1–5090–6255–3/17).
- Lee, M., Hirose, A., Hou, Z.-G., & Kin, R. (2013). *LNCSS 8226 - Neural Information Processing*.
- Li, C. (2016). When does web-based personalization really work? The distinction between actual personalization and perceived personalization. *Computers in Human Behavior*, 54, 25–33. <https://doi.org/10.1016/j.chb.2015.07.049>
- Li, M., Dias, B., El-Deredy, W., & Lisboa, P. (2007). A Probabilistic Model for Item-Based Recommender Systems. *Proceedings of the 2007 ACM Conference on Recommender Systems*,

- (New York: Association for Computing Machinery), 129–132.
<https://doi.org/10.1145/1297231.1297253>
- Lim, Y., & Teh, Y. (2007). Variational Bayesian Approach to Movie Rating Prediction. *Proceedings of KDD Cup and Workshop*, 15–21. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.88.8475&rep=rep1&type=pdf>
- Litvin, S. W., Goldsmith, R. E., & Pan, B. (2008). Electronic word-of-mouth in hospitality and tourism management. *Tourism Management*, 29(3), 458–468.
<https://doi.org/10.1016/j.tourman.2007.05.011>
- Liu, B., & Sun, Y. (2013). Survey of Personalized Recommendation Based on Society Networks Analysis. *Proceedings of 2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering, ICIII 2013*, 3, 337–340.
<https://doi.org/10.1109/ICIII.2013.6703586>
- Liu, D., Lai, C., & Lee, W. (2009). A Hybrid of Sequential Rules and Collaborative Filtering for Product Recommendation. *Information Sciences*, 179(20), 3505–3519.
<https://doi.org/10.1016/j.ins.2009.06.004>
- Liu, J., Dolan, P., & Pedersen, E. (2010). Personalized news recommendation based on click behavior. *Proceedings of the 15th International Conference on Intelligent User Interfaces - IUI '10*, 31. <https://doi.org/10.1145/1719970.1719976>
- Liu, L., Li, Y., Li, S., Hu, N., He, Y., Pong, R., ... Law, M. (2012). Comparison of Next-Generation Sequencing Systems. *Journal of Biomedicine and Biotechnology*, (251364), 11.
<https://doi.org/10.1155/2012/251364>
- Lohr, S. (2009). A 1 \$Million Dollars Research Bargain for Netflix, and Maybe a Model for Others. Retrieved March 28, 2018, from <https://www.nytimes.com/2009/09/22/technology/internet/22netflix.html?pagewanted=all>
- McAuley, J., & Leskovec, J. (2013). Hidden Factors and Hidden Topics : Understanding Rating Dimensions with Review Text. *RecSys '13 Proceedings of the 7th ACM Conference on Recommender Systems*, 165–172. <https://doi.org/10.1145/2507157.2507163>
- McAuley, J., Targett, C., Shi, Q., & Hengel, A. van den. (2015). Image-based Recommendations on Styles and Substitutes.
<https://doi.org/10.1145/2766462.2767755>
- McNamee, P., Piatko, C., & Mayfield, J. (2002). JHU / APL at TREC 2002 : Experiments in

- Filtering and Arabic Retrieval. *Applied Physics*.
- Meo, P., Musial-Gabrys, K., Rosaci, D., Sarnè, G., & Aroyo, L. (2017). Using Centrality Measures to Predict Helpfulness-Based Reputation in Trust Networks. *ACM Transactions on Internet Technology*, 17(1), 1–20. <https://doi.org/10.1145/2981545>
- Mintel. (2015). Seven in 10 Americans seek out opinions before making purchases. *Mintel*, 1–9. Retrieved from <http://www.mintel.com/press-centre/social-and-lifestyle/seven-in-10-americans-seek-out-opinions-before-making-purchases>
- Mizruchi, M. (1994). Social Network Analysis: Recent Achievements and Current Controversies. *Acta Sociologica*, 37(4), 329–343. <https://doi.org/10.1177/000169939403700403>
- Mudambi, S. M., & Schuff, D. (2010). What Makes a Helpful Online Review? A Study of Customer Reviews on Amazon.com. *MIS Quarterly*, 34(1), 185–200. <https://doi.org/Article>
- Muller, E., & Peres, R. (2018). The effect of social networks structure on innovation performance: A review and directions for research. *International Journal of Research in Marketing*, (2017). <https://doi.org/10.1016/j.ijresmar.2018.05.003>
- Newman, J. (2006). Modularity and community structure in networks. *Proceedings of the National Academy of Sciences*, 103(23), 8577–8582. <https://doi.org/10.1073/pnas.0601602103>
- Newman, M. (2003). The Structure and Function of Complex Networks. *SIAM Review*, 45(2), 167–254.
- Nguyen, T.-S., Lauw, H., & Tsaparas, P. (2015). Review Synthesis for Micro-Review Summarization. *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining - WSDM '15*, 2(February), 169–178. <https://doi.org/10.1145/2684822.2685321>
- Park, S.-T., Pennock, D., & DeCoste, D. (2006). Applying Collaborative Filtering Techniques to Movie Search for Better Ranking and Browsing. *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '07*, (American Association for Artificial Intelligence). <https://doi.org/10.1145/1281192.1281252>
- Park, S., & Nicolau, J. (2015). Asymmetric effects of online consumer reviews. *Annals of Tourism Research*, 50, 67–83. <https://doi.org/10.1016/j.annals.2014.10.007>
- Patrick, E. A., & Fischer, F. P. (1970). A Generalized k-Nearest Neighbor Rule. *Information and Control*, 16(2), 128–152. [https://doi.org/10.1016/S0019-9958\(70\)90081-1](https://doi.org/10.1016/S0019-9958(70)90081-1)

- Paul, D., Sarkar, S., Chelliah, M., Kalyan, C., & Nadkarni, P. (2017). Recommendation of High Quality Representative Reviews in e-commerce. *Proceedings of the Eleventh ACM Conference on Recommender Systems - RecSys '17*, 311–315. <https://doi.org/10.1145/3109859.3109901>
- Pires, R. (2017). Visualizações de dados no Software R : Um guia prático . *Universidade Federal de Uberlândia*.
- Portugal, I., Alencar, P., & Cowan, D. (2017). The Use of Machine Learning Algorithms in Recommender Systems: A Systematic Review. *Expert Systems with Applications*, 97, 205–227. <https://doi.org/10.1016/j.eswa.2017.12.020>
- Resnick, P., & Varian, H. R. (1997). Recommender Systems. *Communications of the ACM. Guest Editors*, 40(3), 56–58. <https://doi.org/10.1145/245108.245121>
- Rich, E. (1979). User Modeling via Stereotypes. *Cognitive Science*, 3(4), 329–354. [https://doi.org/10.1016/S0364-0213\(79\)80012-9](https://doi.org/10.1016/S0364-0213(79)80012-9)
- Rodriguez, M., Posse, C., & Zhang, E. (2012). Multiple objective optimization in recommender systems. *Proceedings of the Sixth ACM Conference on Recommender Systems - RecSys '12*, 11. <https://doi.org/10.1145/2365952.2365961>
- Salakhutdinov, R., & Mnih, A. (2007). Probabilistic Matrix Factorization. *Proc. Advances in Neural Information Processing Systems 20 (NIPS 07)*, 1257–1264. <https://doi.org/10.1145/1390156.1390267>
- Sarwar, B., Karypis, G., Konstan, J., & Reidl, J. (2001). Item-Based Collaborative Filtering Recommendation Algorithms Badrul. *Proceedings of the Tenth International Conference on World Wide Web - WWW '01*, (1–58113–348–0/01/0005), 285–295. <https://doi.org/10.1145/371920.372071>
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2000). Analysis of Recommendation Algorithms for E-Commerce. *Proceedings of the 2nd ACM Conference on Electronic Commerce - EC '00*, 158–167. <https://doi.org/10.1145/352871.352887>
- Schafer, B., Konstan, J., & Riedl, J. (2011). Recommender Systems in E-Commerce. *GroupLens Research Project*, (September), 81–90. <https://doi.org/10.1016/B978-0-12-411511-8.00005-0>
- Shimada, K., Tadano, R., & Endo, T. (2011). Multi-aspects Review Summarization with Objective Information. *Procedia - Social and Behavioral Sciences*, 27, 140–149. <https://doi.org/10.1016/j.sbspro.2011.10.592>
- Smyth, B., McCarthy, K., Reilly, J., O'Sullivan, D., McGinty, L., & Wilson, D. (2005). Case-

- Studies in Association Rule Mining for Recommender Systems. *Proceedings of the 2005 International Conference on Artificial Intelligence, ICAI'05*, 2, 809–815. Retrieved from <http://www.scopus.com/inward/record.url?eid=2-s2.0-60749110661&partnerID=tZOtx3y1>
- Souza, E., Peternelli, L., & Mello, M. (2014). Software Livre R : aplicação estatística.
- Steck, H. (2013). Evaluation of Recommendations: Rating-Prediction and Ranking Harald. *Netflix Inc.*, 213–220. Retrieved from <http://dx.doi.org/10.1145/2507157.2507160>.
- Steffes, E., & Burgee, L. (2009). Social ties and online word of mouth. *Internet Research*, 19(1), 42–59. <https://doi.org/10.1108/10662240910927812>
- Su, X., & Khoshgoftaar, T. M. (2009). A Survey of Collaborative Filtering Techniques. *Advances in Artificial Intelligence*, 3, 1–19. <https://doi.org/10.1155/2009/421425>
- Sun, F., Guo, J., Lan, Y., Xu, J., & Cheng, X. (2015). Learning Word Representations by Jointly Modeling Syntagmatic and Paradigmatic Relations. *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, 136–145. <https://doi.org/10.3115/v1/P15-1014>
- Suzuki, R., & Shimodaira, H. (2006). Pvclust: An R package for assessing the uncertainty in hierarchical clustering. *Bioinformatics*, 22(12), 1540–1542. <https://doi.org/10.1093/bioinformatics/btl117>
- Torres, A., & Martins, F. (2014). Book Chaper_Entreprise 2.0_OSN.pdf.
- Wasserman, S., & Faust, K. (1994). Social Network Analysis: Theory and Applications. *Cambridge University Press*, 1, 116. <https://doi.org/10.1525/ae.1997.24.1.219>
- Wu, J., Dai, L., Chiclana, F., Fujita, H., & Herrera-Viedma, E. (2018). A minimum adjustment cost feedback mechanism based consensus model for group decision making under social network with distributed linguistic trust. *Information Fusion*, 41, 232–242. <https://doi.org/10.1016/j.inffus.2017.09.012>
- Xu, P., Chen, L., & Santhanam, R. (2015). Will video be the next generation of e-commerce product reviews? Presentation format and the role of product type. *Decision Support Systems*, 73, 85–96. <https://doi.org/10.1016/j.dss.2015.03.001>
- Yang, Y., Yan, Y., Qiu, M., & Bao, F. S. (2015). Semantic Analysis and Helpfulness Prediction of Text for Online Product Reviews. *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, 38–44. <https://doi.org/10.3115/v1/P15-2007>


- Zanin, M., Papo, D., Sousa, P. A., Menasalvas, E., Nicchi, A., Kubik, E., & Boccaletti, S. (2016). Combining complex networks and data mining: Why and how. *Physics Reports*, 635, 1–44. <https://doi.org/10.1016/j.physrep.2016.04.005>
- Zhang, L. (2015). Online Reviews: The Impact of Power and Incidental Similarity. *Journal of Hospitality Marketing and Management*, 24(6), 633–651. <https://doi.org/10.1080/19368623.2014.929550>
- Zhao, Q., Zhang, Y., Friedman, D., & Tan, F. (2015). E-commerce Recommendation with Personalized Promotion. *Proceedings of the 9th ACM Conference on Recommender Systems - RecSys '15*, 219–226. <https://doi.org/10.1145/2792838.2800178>
- Zhao, T., McAuley, J., Li, M., & King, I. (2017). Improving Recommendation Accuracy using Networks of Substitutable and Complementary Products. *Proceedings of the International Joint Conference on Neural Networks*, 3649–3655. <https://doi.org/10.1109/IJCNN.2017.7966315>
- Zhuang, M., Cui, G., & Peng, L. (2018). Manufactured opinions: The effect of manipulating online product reviews. *Journal of Business Research*, 87(February 2017), 24–35. <https://doi.org/10.1016/j.jbusres.2018.02.016>

Anexos

- I. A natureza do trabalho apresenta um caráter monográfico, focalizando-se num tema em particular.
- II. O estilo utilizado nas referências bibliográficas é o APA 6th.

Anexo 1

Figura 1 - *Reviews* de um produto no Epinions.com

| | |
|--|---|
| <div>Epinions 🌱 🌿 🍃 🍄</div> <div>Search for products and reviews</div> | |
|  | <p>Aveeno Radiant Skin Daily Moisturizer</p> <p>★ ★ ★ ★ ☆ 14 Reviews</p> |
| <div>Consumer Reviews</div> <div><p>Positively Radiant Daily Moisturizer ... Are You Sure???</p><p>Review by ms_pookie</p><p>★ ★ ★ ☆ ☆ August, 04 2003</p><p>Pros: SPF 15, fast absorbing</p><p>Cons: Poor dispensing, expensive for drug store brand, leaves skin oily</p></div> <div><p>I'm glowing, and it is not post-coital!!</p><p>Review by adamsjill</p><p>★ ★ ★ ★ ★ June, 27 2003</p><p>Pros: makes my skin look glowing not glittery, smooths skin, SPF 15</p><p>Cons: expensive, not unscented</p></div> <div><p>Aveeno Radiant Skin Daily Moisturizer- Flakes be gone!</p><p>Review by xxskagirlxx</p><p>★ ★ ★ ★ ☆ May, 25 2006</p><p>Pros: Lightly moisturizing, easy to apply, SPF, banished my flaking!</p><p>Cons: Can make skin a little shiny, spendy for a drugstore brand.</p></div> | |

Anexo 2

Figura 2 - “Esta *review* foi útil para ti?”: Exemplo exportado da Amazon.com a 04 de abril, 2018

 Alex T.


★★★★★ **My favorite speaker so far**

June 17, 2017

Color: black | **Verified Purchase**

My favorite speaker so far! I have been looking for a Bluetooth speaker I will be able to listen to music in many different places: bathroom, bedroom, the beach, and other open areas open to the public. I wanted something that is not too expensive but also had good quality.

Therefore, I went to BestBuy to look at the right speaker. In the beginning, I was interested in the JBL 3, but after listening to both speakers, I couldn't choose the JBL over the Sony. Sony's bass, quality, and overall look were better in every way. Plus it ways cheaper. That's why I chose Sony.



[Comment](#) | 27 people found this helpful. Was this review helpful to you? [Report abuse](#)

Anexo 3

Tabela 1 - Alguns estudos relacionados com a área

| Autores (ano) | Artigo | Principal Objetivo | Técnicas Utilizadas | Principais Conclusões |
|--|---|--|---|---|
| Oestreicher-Singer e Sundararajan (2012) | <i>Recommendation Networks and the long tail of Eletronic Commerce</i> | Medir até que ponto um produto é influenciado pela sua posição na rede de recomendações – testar o efeito da “cauda longa” | Uso de distribuições de receita de livros da Amazon.com de mais de 200 categorias distintas. | O estudo revela que a duplicação da influência media da rede de uma categoria está associada a um aumento médio de cerca de 50% na receita relativa dos 20% dos produtos menos populares. |
| Centeno et al. (2018) | <i>From textual reviews to Individual Reputation Rankings: Leaving ratings aside solving MPC task</i> | Estimar com mais precisão as preferências individuais dos utilizadores, através da analise dos problemas decorrentes da solução da tarefa de classificação de Polaridade Multiway, mapeando reviews nos sistemas de reviews online | Apresentação de uma abordagem baseada na construção – Classificações de Reputação Individual (IRRs) para cada utilizador. | O mecanismo IRR é capaz de capturar as preferências dos utilizadores, criando classificações individuais de reputação para cada utilizador no sistema. |

| | | | | |
|--------------------------|---|--|--|--|
| Meo <i>et al.</i> (2017) | <i>Using Centrality Measures to Predict Helpfulness-Based Reputation in Trust Networks</i> | Responder à questão: É possível identificar as relações de confiança através das reviews mais úteis? | Dados reais extraídos do CIAO e do Epinions – aplicando cinco medidas de popularidade de centralidade. | Os autores concluíram que se pode alavancar as relações de confiança para identificar os utilizadores que produzem as <i>reviews</i> mais úteis para toda a comunidade. |
| Filieri (2016) | <i>What makes an online consumer review trustworthy?</i> | Identificar o nível de confiabilidade dos consumidores nas reviews online | 38 entrevistas com utilizadores de compras online | Os resultados evidenciam que os consumidores usam principalmente dicas relacionadas ao conteúdo e ao estilo da mensagem. |
| Ghose e Ipeirotis (2011) | <i>Estimating the Helpfulness and Economic Impact of Product Reviews: Mining Text and Reviewer Characteristics.</i> | Examinar o impacto das reviews nos resultados económicos, como as vendas de produtos | Explora vários aspetos das da review, como níveis de subjetividade, várias medidas de legibilidade e extensão da grafia. | Uma diminuição do desvio da probabilidade de comentários subjetivos está associado a um aumento nas vendas dos produtos. Um aumento na proporção de erros ortográficos, diminui as vendas dos produtos. Quando o texto é informativo e detalhado, também revela um aumento nas vendas. |

| | | | | |
|-----------------------------------|---|--|---|---|
| Kim <i>et al.</i> , (2017) | <i>Online serendipity: The case for curated recommender systems</i> | Sistema de recomendação que facilita recomendações de toque pessoal, permitindo que os utilizadores descubram bons recomendadores, em vez de se concentrar em recomendar itens algoritmicamente. | Um sistema que descobre curadores, e curadores que fazem recomendações. | Um sistema com curadoria é ideal para retalhistas e prestadores de serviços, especialmente aqueles que vendem livros, transmitem conteúdo ou fornecem plataformas de redes sociais. |
| Adomavicius e Kwon (2012) | <i>Improving Aggregate Recommendation Diversity Using Ranking-Based Techniques</i> | Apresentação de uma série de técnicas de recomendação substancialmente mais diversas para todos os utilizadores, mantendo comparáveis níveis de precisão e recomendação. | Neighborhood-Based CF Technique; | Ganhos com a diversidade da proposta de técnicas que utilizam vários conjuntos de dados de classificação do mundo real e diferentes algoritmos de previsão de classificação. |
| Gomez-Uribe e Hunt (2015) | <i>The Netflix Recommender System: Algorithms, Business Value, and Innovation</i> | Melhorar os algoritmos de recomendação, combinando testes A/B focados em melhorar a retenção de membros e envolvimento a médio prazo. | A/B testing | Este modelo ajuda significativamente as pessoas a tomarem melhores decisões, em áreas significativas, procura de emprego, educação, planos de seguro, etc. |
| T. Zhao <i>et al.</i> , (2017) | <i>Improving Recommendation Accuracy using Networks of Substitutable and Complementary Products</i> | Construir um modelo recomendador que modelam relacionamentos entre produtos. | Seleção de categorias de produtos: Bebê, Beleza, Eletrónica, Casa e Cozinha, Filmes e TV. As redes de substituição são extraídas da co-navegação, indicando uma relação de | O quadro proposto melhora significativamente a precisão da estimativa de classificação e pode ser aplicada para conjuntos de dados em larga escala. |

| | | | | |
|---------------------------|---|--|--|---|
| | | | similaridade entre os itens. | |
| McAuley e Leskovec (2013) | <i>Hidden Factors and Hidden Topics: Understanding Rating Dimensions with Review Text</i> | Combinação do rating (como as dos sistemas de recomendação de fatores latentes) com tópicos de review (modelos de tópicos como LDA) | Obtenção de rótulos textuais; avaliar os produtos, aproveitando a informação presente nas reviews. - Modelo HFT | O modelo HFT descobre tópicos de produtos altamente interpretáveis, que podem ser usados para facilitar tarefas como a descoberta do gênero e sugerir reviews informativas. |
| Chua e Banerjee (2016) | <i>Helpfulness of user-generated reviews as a function of review sentiment, product type and information quality.</i> | Responder às questões: A utilidade das reviews criadas pelo utilizador varia em função do sentimento da review e do tipo de produto? | Dados de 2190 reviews da Amazon de produtos como: camaras, telefones, impressoras | Os autores descobriram que descobriram que a relação entre a qualidade da informação e a utilidade da <i>review</i> varia em função do produto e da <i>review</i> (favorável, desfavorável e misto). Estas descobertas indicam que o tipo de produto que está a ser estudado também é um fator importante quando se estuda os indicadores da utilidade. |